



UNIVERSIDADE DO PORTO
FACULDADE DE CIÊNCIAS

Moisés Vungo

**Reconhecimento Automático de Sinais de Trânsito em Imagens
Digitais**

Departamento de Matemática
Faculdade de Ciências do Porto

Abril, 2017

UNIVERSIDADE DO PORTO
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE MATEMÁTICA
MESTRADO EM ENGENHARIA MATEMÁTICA

Moisés Vungo

**Reconhecimento Automático de Sinais de Trânsito em Imagens
Digitais**

*Dissertação submetida à Faculdade de
Ciências da Universidade do Porto para
obtenção do grau de Mestre em Engenharia
Matemática*

**Trabalho efetuado sob orientação do Professor
Doutor André Ribeiro da Silva de Almeida
Marçal**

Faculdade de Ciências do Porto

Abril, 2017

Agradecimentos

Os meus agradecimentos primordiais ao Deus todo poderoso criador do Céu e da Terra por ajudar me chegar nesta fase, porque sem ele tendo em conta as dificuldades vividas neste percurso, este trabalho não teria lugar.

Ao meu orientador Prof. André Ribeiro da Silva de Almeida Marçal, por sempre me ter recebido no seu gabinete com boa disposição e um contagioso entusiasmo, transmitindo-me toda a confiança, estímulo e vontade necessária. Por todas as suas críticas e sugestões que se demonstraram fundamentais na realização deste trabalho. O meu muito obrigado e que Deus digne abençoar-te ricamente.

À minha família, por toda a dedicação, apoio e coragem que me transmitiram, mesma à distância não me desampararam desde o primeiro momento, em especial a minha digníssima esposa Octávia Quiuma Malalo Nzau Vungo por toda a compreensão e tolerância demonstrada durante este longo período da minha ausência e longe de casa, suportou os meus filhos no seu dia-a-dia para que este objetivo fosse atingido. Aos meus filhos, que perderam o carinho habitual durante este período da minha formação e que todos os dias perguntavam quando é que poderia voltar em casa.

Quero também agradecer ao corpo docente da FCUP, em particular os do curso de Engenharia Matemática que com paciência e dedicação souberam trabalhar connosco, especialmente a coordenação.

Por fim gostaria de estender os meus agradecimentos presenteando todos os meus amigos cá no Porto, os de Angola, que direta ou indiretamente ajudaram durante esta formação, dirijo-lhes uma palavra de carinho por toda paciência, apoio, cuidado e amizade que demonstraram ao longo de todo este percurso. Porque sem vocês este percurso seria mais complexo.

A todos os meus sinceros agradecimentos, que Deus digne abençoar-vos!

Epígrafe

“Todo aquele que se dedica ao estudo da ciência chega a convencer-se de que nas leis do Universo se manifesta um Espírito sumamente superior ao do homem, e perante o qual nós, com os nossos poderes limitados, devemos humilhar-nos.”

Albert Einstein

Resumo

Nesta dissertação foi desenvolvido um método de reconhecimento e classificação de sinais de trânsito, nomeadamente da sinalização de perigo e alguns da regulamentação, previamente identificados em imagens digitais obtidas nas bases de dados GTSRB (German Traffic Sign Recognition Benchmark) e da FCUP (Faculdade de Ciências da Universidade do Porto).

A metodologia desenvolvida no reconhecimento de sinalização vertical de trânsito funciona nas etapas após aquisição e processamento, que consistem em extrair as características dos sinais, a partir de histogramas das componentes binárias das cores vermelha, azul e preta da imagem original, após de ter sido convertida no espaço HSV. Posteriormente faz-se uma classificação das imagens baseada por cada tipo da imagem da sua classe. Esta metodologia é constituída por três fases; a aquisição ou entrada da imagem, que consiste na extração da imagem na base de dados, que é feita por uma função criada no MATLAB, utilizando um processo de segmentação por cor e consequentemente a sua binarização. A fase da classificação, que tem como base as regiões de interesse obtidas na fase de anterior e consiste no reconhecimento da forma geométrica de cada região, bem como na agregação por classes de cada uma dessas regiões de interesse analisadas e que são baseadas na cor e forma geométrica. E na fase de reconhecimento, consiste na identificação da sinalização que teve entrada e classificada, fazendo uma correspondência dos pixels presentes no sinal.

O método implementado foi testado com duas (2) bases de dados: GTSRB e FCUP. No reconhecimento das imagens da base de dados GTSRB apurou-se uma precisão de 72.2% para 26 classes, num total correspondente de 1300 imagens de teste e 260 imagens do treino, o que perfaz um total de 1560 imagens selecionadas aleatoriamente nesta base de dados. Enquanto que nas imagens da base de dados da FCUP apresentou uma taxa de 55% para 26 classes, numa soma correspondente de 182 imagens de teste e 78 imagens do treino, o que perfaz um total de 260 imagens. Não obstante os resultados obtidos apresentarem taxas percentuais um pouco abaixo de algumas pesquisas dos últimos anos, mas por estarem acima da média nos deixam satisfeitos e com alta estima em prosseguir nesta linha de pesquisa.

Palavras-chave:

Reconhecimento automático; Classificação de imagens; Sinalização vertical de trânsito; Segmentação de imagens.

Abstract

In this dissertation a method of recognition and classification of traffic signs, of danger signaling and some of regulation, previously identified in digital images obtained in the GTSRB (German Traffic Sign Recognition Benchmark) and FCUP (Faculty of Sciences of the University of Porto) database was developed.

The developed methodology of recognition of vertical traffic signaling works in mode after acquisition and processing, is to extract the characteristics of the signals, from histograms of the binary components of the colors red, blue and black of the original image, after being converted to the HSV color. Subsequently a reasonable classification of the images is made based on each type of the image class. This methodology consists of three phases: the acquisition or input of the image, which consists of extracting the image in the database, which is done by a function created in MATLAB, using a process of color segmentation and consequently its binarization. The classification phase, which is based on the regions of interest obtained in the previous phase and consists of the recognition of the geometric form of each region, as well as in the aggregation by classes of each of these analyzed regions of interest and that are based on the color and geometric form. And in the recognition phase, it consists in the identification of the signaling that has entered and classified.

The methodology implemented was tested with two (2) databases: GTSRB and FCUP. The recognition of the GTSRB database images an accuracy of 72.2% was obtained for 26 classes, in a corresponding total of 1300 test images and 260 training images, which makes a total of 1560 randomly selected images in this database of data. While in the images of the database of FCUP presented a rate of 55% for 26 classes, in a corresponding sum of 182 test images and 78 images of the training, which makes a total of 260 images randomly selected in this database. Although the results obtained that present percentage rates a little below some surveys of recent years, because they are above the average they leave us satisfied and with high esteem to continue in this line of research.

Key words:

Automatic recognition; classification of images; vertical traffic signs; segmentation of images.

Índice

AGRADECIMENTOS	I
EPÍGRAFE	II
RESUMO.....	III
ABSTRACT	IV
ÍNDICE	V
LISTA DE ACRÓNIMOS	VII
LISTA DE FIGURAS	VIII
LISTA DE TABELAS.....	X
CAPÍTULO 1- INTRODUÇÃO	1
1.1.Enquadramento e Objetivos.....	2
1.2.Estrutura do relatório.....	3
CAPÍTULO 2- RECONHECIMENTO DE SINAIS DE TRÂNSITO.....	5
2.1. Sinalização Vertical de Trânsito.....	5
2.1.1. Sinais de Perigo	6
2.1.2. Sinais de Regulamentação.....	6
2.2. Modelos de Cor.....	8
2.3. Segmentação e Binarização.....	11
2.4. Sistemas de Detecção e Reconhecimento de Sinais de Trânsito.....	13
CAPÍTULO 3- METODOLOGIA.....	22

3.1. Disposição dos Elementos Metodológicos.....	22
3.2. Pré-processamento das Imagens.....	23
3.3. Aplicação da Segmentação e Binarização.....	26
3.4. Extração das Caraterísticas de Sinais.....	27
3.4.1. Projeções de Imagens Binárias na direção Horizontal e Vertical.....	28
3.4.2. Normalização dos vetores.....	29
3.5. Reconhecimento.....	31
3.5.1. Dificuldades durante o reconhecimento	32
3.5.2. Treino.....	32
3.5.3. Classificação.....	33
CAPÍTULO 4- AVALIAÇÃO EXPERIMENTAL.....	34
4.1. Conjunto de dados.....	34
4.2. Estratégia de Avaliação.....	34
4.3. Resultados na Base de Dados GTSRB.....	36
4.4. Resultados na Base de Dados da FCUP.....	38
4.5. Discussão dos Resultados.....	40
CAPÍTULO 5- CONCLUSÕES	46
REFERÊNCIAS	48
ANEXO A – ASSINATURAS DAS COMPONENTES DE CADA CLASSE DE GTSRB ..	51
ANEXO B – ASSINATURAS DAS COMPONENTES DE CADA CLASSE DE FCUP	59
ANEXO C – IMAGENS REPRESENTATIVAS DA BASE DE DADOS GTSRB.....	71
ANEXO D- IMAGENS DA BASE DE DADOS FCUP.....	75

Lista de Acrónimos

ADAS – Sistemas avançados de condução assistida (Advanced Driver Assistance Systems)

API – Interface de programação de aplicativos (Application Programming Interface)

FCUP – Faculdade de Ciências da Universidade do Porto

GPS – Sistema de Posicionamento Global (Global Positioning System)

GTSRB – Referência de reconhecimento do sinal de trânsito alemão (German Traffic Sign Recognition Benchmark)

HOG – Histogramas de Gradiente Orientados

HSI – Espaço de cores da tonalidade, saturação, intensidade (Hue Saturation Intensity)

HSV – Espaço de cores da tonalidade, saturação, valor (Hue Saturation Value)

INIR – Instituto Nacional de Infra-Estrutura Rodoviária

LSS – Sistema de Similaridade Local

MMS/SMM – Sistema de Mapeamento Móvel (Mobile Mapping System)

MP – Perseguição correspondente (Matching Pursuit)

RASVT – Reconhecimento Automático de Sinais Verticais de Trânsito

RdI – Região de Interesse da imagem (Region of interest)

RGB – Espaço de cores vermelho, verde, azul (Red Green Blue)

ROI – Região de Origem de Interesse

SIFT – Transformação de recursos invariantes (Scale Invariant Feature Transform)

SIG – Sistema de informação geográfica

SVM – Máquina de Vetores de Suporte

SVT – Sinalização vertical de trânsito

TSR/RST – Reconhecimento de Sinais de Trânsito (Traffic Signs Recognition)

Lista de figuras

FIGURA 1- SINAIS DE PERIGO COM CARACTERÍSTICAS DIFERENTES DA GENERALIDADE: A) A32A E B) A32B.	6
FIGURA 2- SINAIS DE CEDÊNCIA DE PASSAGEM QUE APRESENTAM FORMAS E CORES DISTINTAS.	6
FIGURA 3- SINAIS DE PROIBIÇÃO: (A) SINAIS COM CARACTERÍSTICAS TÍPICAS DE PROIBIÇÃO. (B) PARAGEM E ESTACIONAMENTO PROIBIDOS. (C) REPRESENTAÇÃO DE FIM DE PROIBIÇÃO. ..	7
FIGURA 4- SINALIZAÇÃO DE OBRIGAÇÃO: A) SINAIS DE OBRIGAÇÃO. B) SINAIS DE FIM DE OBRIGAÇÃO.	7
FIGURA 5- SINAIS DE PRESCRIÇÃO ESPECÍFICA: A) SINAIS DE SELEÇÃO DE VIAS – E1 A E3. B) SINAIS DE AFETAÇÃO DE VIAS – F1 E F2. C) SINAIS DE ZONA - G1 A G9.....	7
FIGURA 6- CUBO DO MODELO RGB.	8
FIGURA 7- MISTURAS DE CORES DO MODELO RGB.	8
FIGURA 8- MODELO DE COR DE HSV: A) REPRESENTADO COM HEXACONE (FOLEY 1997); B1) COMO CONE E B2) VISTA DE UM SEGMENTO DO CONE HSV- (PIERCE, 2004).....	10
FIGURA 9- PASSOS FUNDAMENTAIS EM PROCESSAMENTO DE IMAGENS DIGITAIS.	11
FIGURA 10- ESQUEMA DA METODOLOGIA DA CLASSIFICAÇÃO.	22
FIGURA 11- ESQUEMA DA METODOLOGIA DA FASE DE TREINO.....	23
FIGURA 12- EXEMPLO DE UMA IMAGEM RGB - A) E SUA COMPONENTES R - B), G - C) E B - D). 25	
FIGURA 13- EXEMPLO DE UMA IMAGEM HSV - A) E SUA COMPONENTES H - B), S - C) E V - D). 25	
FIGURA 14- EXEMPLO DA CONVERSÃO DA IMAGEM RGB PARA HSV, SENDO A IMAGEM HSV APRESENTADA COMO COMPOSIÇÃO RGB.	26
FIGURA 15- IMAGEM RGB A), IMAGEM BINÁRIA VERMELHA B), IMAGEM BINÁRIA AZUL C), IMAGEM BINÁRIA PRETA D) E ZONA DO SINAL E).	27
FIGURA 16- IMAGEM BINÁRIA A), HISTOGRAMAS DE LINHAS B) E COLUNAS C) E VERSÕES NORMALIZADAS (PARA N=10), PARA LINHAS D) E COLUNAS E).	29
FIGURA 17- IMAGEM ORIGINAL A), IMAGEM BINÁRIA VERMELHA B), IMAGEM BINÁRIA AZUL C), IMAGEM BINÁRIA PRETA D).....	30
FIGURA 18 - HISTOGRAMA DE LINHAS A) E COLUNAS B) PARA IMAGEM BINÁRIA VERMELHA E VERSÕES NORMALIZADAS PARA LINHAS C) E COLUNAS D).	30
FIGURA 19 - HISTOGRAMA DE LINHAS A) E COLUNAS B) PARA IMAGEM BINÁRIA AZUL E VERSÕES NORMALIZADAS PARA LINHAS C) E COLUNAS D).	31
FIGURA 20 - HISTOGRAMA DE LINHAS A) E COLUNAS B) PARA IMAGEM BINÁRIA PRETA E VERSÕES NORMALIZADAS PARA LINHAS C) E COLUNAS D).	31
FIGURA 21- SINAIS DE TRÂNSITO COM PERFIS PADRÕES IGUAIS.	32

FIGURA 22- COMPARAÇÃO DE SINAIS STANDARD COM OS QUE FORAM USADOS NAS BASES DE DADOS.....	35
FIGURA 23- ALGUNS EXEMPLOS DAS MESMAS CLASSES COM DIVERSIFICAÇÃO.	36
FIGURA 24- IMAGEM DA GTSRB A), IMAGEM STANDARD B), IMAGEM DA FCUP C).	41
FIGURA 25- IMAGENS DA GTSRB: ORIGINAL A), BINÁRIA VERMELHA B) E BINÁRIA PRETA C). ...	42
FIGURA 26- IMAGENS DA FCUP: ORIGINAL A), BINÁRIA VERMELHA B) E BINÁRIA PRETA C).....	42
FIGURA 27- IMAGENS ORIGINAL A), BINÁRIA VERMELHA B), BINÁRIA AZUL C), BINÁRIA PRETA D) E ZONA DO SINAL E).	43
FIGURA 28- IMAGENS DA GTSRB: ORIGINAL A), BINÁRIA VERMELHA B) E BINÁRIA PRETA C). ...	43
FIGURA 29- IMAGENS DA FCUP: ORIGINAL A), BINÁRIA VERMELHA B) E BINÁRIA PRETA C).....	43
FIGURA 30- IMAGEM APENAS COM AZUL A), IMAGEM APENAS COM VERMELHA B), IMAGEM COM VERMELHA E PRETA C), IMAGEM COM AZUL E PRETA D), IMAGEM COM VERMELHA AZUL E).	45

Lista de Tabelas

Tabela 1 – Resultados teste na base de Dados GTSRB	37
Tabela 2 – Matriz de confusão das imagens da base de dados da GTSRB	38
Tabela 3 – Resultados teste na base de Dados da FCUP	39
Tabela 4 – Matriz de confusão das imagens da base de dados da FCUP	40

Capítulo 1- Introdução

A sucessão gradual de transformações tecnológicas da atualidade se afiguram como principal mola impulsionadora das economias ao nível mundial, designadamente no que diz respeito ao progresso das indústrias eletrónicas. Neste contexto, a inovação computacional e dos dispositivos de imagem têm disposto regularmente uma crescente aplicação na visão computacional nesta área.

Conforme esta perspetiva, é imprescindível a utilização dos sistemas computacionais possíveis que forneçam um desempenho elevado, aliado a uma maior segurança do condutor são sem dúvida uma mais-valia e, um sistema de reconhecimento de sinais de trânsito, não será exceção. Para tal, são necessários um conjunto de dados que disponibilizam informação, tais como sinais de trânsito que servirão como orientadores dos condutores nas estradas. Por isso a maioria das investigações feitas nesse campo tem sido na deteção automática de sinais de trânsito e sistemas de reconhecimento, com uma vasta gama de aplicações tais como: condução automática, sistemas de assistência a condutores e inventário automático de estradas.

O reconhecimento de sinais de trânsito na atualidade é o sistema computacional muito estudado para o apoio aos condutores e para automatização das tarefas de recolha de dados para criar ou atualizar um Sistema de Informação Geográfica (SIG) de interesse, tais como caixas de correio, paragens de autocarro, sinais de trânsito. A abordagem convencional para a extração de imagens a partir de um Sistema de Mapeamento Móvel (SMM) é de ter um operador que visualiza as imagens de vídeo e identifica os objetos de interesse. Quando um objeto relevante é encontrado, o vídeo é parado e os pixéis da imagem é selecionados (Alves, 2004).

O sistema identifica o ponto conjugado na outra imagem do par estereoscópico, com a posição e a altitude gravada pelo GPS, calcula as coordenadas geográficas do objeto identificado. O operador deve então fornecer os atributos do objeto a ser inserido na base de dados (ex.: o tipo de sinal de). Um sistema de reconhecimento automático de objetos pode ser um importante apoio para esse processo, através de: (1) identificação de objetos de interesse na imagem e/ou (2) reconhecimento do tipo de objeto ou atributos relevantes (Gonçalves, 2009).

Este está baseado na aquisição de imagens do meio envolvente aos automóveis, através de câmaras direcionadas para as zonas onde provavelmente estão os sinais de trânsito. Após a captura, estas imagens passam numa aplicação de métodos e técnicas que visam o reconhecimento e identificação de sinais de trânsito. Depois de ser

identificados, o condutor é advertido a sua presença, através de uma aplicação visual ou sonora. Este sistema transmite uma maior segurança ao condutor na medida em que existem muitas distrações possíveis que tomarão os condutores mais vulneráveis a acidentes rodoviários. Convém salientar que existem algumas adversidades que afetam o desempenho do sistema. A inclinação dos sinais, a sua fraca localização e problemas relacionados com luminosidade são algumas condicionantes para eficaz deteção e funcionamento do processo (Sampaio, 2010).

A identificação de sinais de trânsito poderá ser efetuada de variadíssimas formas. Não existe atualmente um método a seguir, ideal ou perfeito para o fazer. Existem sim técnicas que se adaptam para desta forma tornar um determinado sistema mais rápido e sobretudo eficaz, ora não estivesse em causa a segurança rodoviária do condutor. Prover uma máquina de um dos sentidos mais importantes do ser humano, é sem sombra de dúvidas um grande desafio. É insuficiente aplicar meras alterações às imagens capturadas. É necessário desenvolver sistemas capaz de interpretar essas imagens.

1.1. Enquadramento e Objetivos

O tráfego rodoviário assume nos dias de hoje, uma grande importância na organização da sociedade. De modo a garantir a correta circulação dos veículos e a segurança de bens humanos e materiais, cada governo adaptou convenções e normas específicas de regulamentação rodoviária. Alguma dessas regras são comunicadas aos condutores através de sinalização vertical de trânsito (SVT). A correta e rápida interpretação da SVT, durante a condução tem um papel fundamental na segurança do próprio condutor, bem como na segurança dos restantes utilizadores do meio rodoviário (Da Silva et al, 2013).

Por causa da importância da SVT, surge a necessidade da existência de entidades públicas, ou privadas (concessionárias), que detêm obrigações legais na correta sinalização das vias rodoviárias e na manutenção do bom estado de conservação dessa mesma sinalização e que poderão ser responsabilizadas em caso de incumprimento. Tendo em conta estes pressupostos, existe a necessidade, tanto por parte das concessionárias, como dos institutos públicos responsáveis, de efetuar uma monitorização periódica à sinalização presente nas vias rodoviárias sob a sua alçada. Uma das possibilidades que atualmente é utilizada para realizar este tipo de monitorização baseia-se nos sistemas de mapeamento móvel (SMM), que identifica a sinalização de forma manual por parte de um operador, já que não está disponível no mercado *software* que reconhece automaticamente os sinais de trânsito. Desta forma, torna-se pertinente o

desenvolvimento de uma aplicação que automatize este processo de reconhecimento de SVT.

O presente trabalho baseia-se em imagens digitais recolhidas nas bases de dados GTSRB (German Traffic Sign Recognition Benchmark) e da FCUP (Faculdade de Ciências da Universidade do Porto). Os sinais a que o sistema se propõe reconhecer são os sinais de perigo e os sinais de regulamentação nas duas bases de dados. Onde na GTSRB temos apenas os sinais de cedência de passagem, sinais de obrigação e alguns sinais de proibição. Enquanto que na base de dados da FCUP já constam sinais de informação.

O objetivo deste trabalho é desenvolver um método de reconhecimento automático de sinalização vertical de trânsito (RASVT), da base de dados GTSRB nomeadamente da sinalização de perigo e alguma da sinalização de regulamentação (cedência de passagem, proibição e obrigação) que possuem as cores vermelha, azul e preta. Para tal, o problema será abordado da seguinte forma:

- Implementar o algoritmo proposto por (Gonçalves, 2009) adaptando-o às características da base de dados GTSRB.
- Comparar o desempenho da classificação e reconhecimento dos dois conjuntos de dados.

1.2. Estrutura do relatório

O relatório desta dissertação encontra-se estruturado em cinco capítulos.

No primeiro capítulo baseou-se numa introdução onde se apresentam o enquadramento geral e o seu principal objetivo a atingir.

O segundo capítulo descreve as técnicas de processamento de imagens, e reconhecimento de sinais de trânsito em imagens digitais e algumas pesquisas atualmente existentes.

Como terceiro capítulo, referencia à metodologia desenvolvida, mais concretamente ao pré-processamento, à segmentação e binarização, à extração de características, e ao reconhecimento.

No quarto capítulo faz-se uma avaliação experimental, baseada no conjunto das bases de dados das imagens, identificando assim os diferentes tipos de sinais em estudo. Experimentar os vários estudos realizados em função da variação de alguns dos parâmetros das imagens, como; o número de imagens de treino, os intervalos de normalização, os resultados de cada base de dados (GTSRB e FCUP).

No quinto capítulo são apresentadas as conclusões tiradas com o trabalho realizado e a referência a algumas perspectivas de trabalho futuro.

Capítulo 2- Reconhecimento de sinais de trânsito

A importância relevante da sinalização rodoviária traduz uma boa fluidez e correta circulação do trânsito e todos os demais utentes da via pública. Nos locais onde a via possa oferecer perigo para o trânsito, onde este esteja sujeito a restrições ou precauções, ainda simplesmente quando se mostra relevante informar os utentes da via, é utilizada a sinalização rodoviária para assim ajudar todos os que interferem direta e indiretamente na circulação rodoviária.

Ao falar da sinalização rodoviária, normalmente associa-se aos sinais verticais e os sinais luminosos, vulgarmente chamados de semáforos. No entanto a sinalização rodoviária abrange bem mais que isso. As marcas rodoviárias, os sinais dos agentes reguladores do trânsito, os dos condutores bem como os sinais temporários, fazem todos eles parte da sinalização rodoviária. Para evitar situações de embaraço no trânsito, foi estabelecido uma hierarquia entre as prescrições com uma cronologia de prevalência ordenada de seguinte forma: (Sampaio, 2010).

- 1- Ordens dos agentes reguladores do trânsito.
- 2- Sinalização
 - 2.1- Sinalização temporária
 - 2.2- Sinalização luminosa (semáforos)
 - 2.3- Sinalização vertical
 - 2.4- Marcas rodoviárias

2.1. Sinalização Vertical de Trânsito

A sinalização de trânsito não é mundialmente uniformizada, existindo diferentes sistemas de sinais consoante a região do mundo sob análise. O sistema de sinalização vertical de trânsito (SVT) na maior parte dos países evoluiu de forma lenta, com alterações esporádicas e muitas vezes impulsionadas por acordos internacionais.

Atualmente para além das marcas rodoviárias, os sinais que são mais comuns nas vias públicas são os sinais verticais. É por eles que a maioria dos condutores se regem para assim adaptarem a sua condução às diversas situações que o trânsito e a via apresentam. Neste contexto, o sistema desenvolvido neste trabalho tem como objetivo a deteção e reconhecimento dos sinais de trânsito que revelam maior importância no auxílio à condução.

2.1.1. Sinais de Perigo

Os sinais de perigo indicam aos utentes da via pública a existência ou a possibilidade de aparecimento de condições especialmente perigosas para o trânsito que imponham particular atenção e prudência ao condutor. Existem no geral um total de quarenta e quatro (44) sinais de perigo, todos com a forma triangular e com bordado de cor encarnado. No seu interior encontra-se uma figura padrão de cor preta sobre um fundo branco, que os distingue. Apesar disso, existem dois (2) sinais de perigo que são exceção à regra. Refere-se do sinal de “local de passagem de nível sem guarda” e o de “local de passagem de nível sem guarda com duas ou mais vias”, que não podem ser colocados na proximidade imediata da passagem de nível e cujos códigos atribuídos segundo o regulamento do código de estrada internacional são respetivamente, A32a e A32b. (Sampaio, 2010). Conforme representado a figura abaixo.



Figura 1- Sinais de perigo com características diferentes da generalidade: a) A32a e b) A32b.

2.1.2. Sinais de Regulamentação

Os sinais de regulamentação subdividem-se em sinais de cedência de passagem, sinais de proibição, sinais de obrigação e sinais de prescrição específica.

Invicta (2002) diz que os sinais de cedência de passagem têm as formas diversificadas podendo ser circulares, triangulares, quadrangulares ou hexagonais, apresentando cor vermelha, branca, azul e/ou amarela. E informam os condutores da existência de cruzamento, entroncamento, rotunda ou passagem estreita, onde lhes é imposta uma especial atenção. Existem, no entanto, uma predominância de sinais triangulares orlados a vermelho, com pictograma preto sobre fundo branco.



Figura 2- Sinais de cedência de passagem que apresentam formas e cores distintas.

Os sinais de proibição apresentam uma forma circular, normalmente orlada a vermelha, com ou sem pictograma sobre fundo branco. No entanto existem algumas exceções, como os sinais de proibição de estacionamento e/ou paragem, que apresentam

um fundo azul, ou os sinais de fim de proibição que não se apresentam orlados a vermelho, sendo branco com traços diagonais pretos e pictograma cinzento, conforme a figura 3.




Figura 3- Sinais de proibição: (a) Sinais com características típicas de proibição. (b) Paragem e estacionamento proibidos. (c) Representação de fim de proibição.

Os sinais de obrigação apresentam forma circular, cor azul e pictograma branco, podendo ou não ter um traço diagonal a vermelho que representa o fim de uma obrigação específica, como apresenta na figura abaixo.



Figura 4- Sinalização de obrigação: a) Sinais de obrigação. b) Sinais de fim de obrigação.

Os sinais de prescrição específica transmitem aos utentes a imposição ou proibição de determinados comportamentos e abrangem os sinais de seleção de vias (E1 a E3), sinais de afetação de vias (F1 e F2) e sinais de zona (G1 a G9). A indicação de um destino deve estar sempre associada à indicação da estrada que o serve e deve ser inscrito entre parêntesis, quando o acesso a esse destino não for direto. O sinal de zona deve ser colocado em todos os acessos à área que se pretende ordenar, devendo todas as saídas, com exceção da zona de trânsito proibido, ser sinalizadas com o respetivo sinal de fim de zona, o qual pode ser apostado do lado esquerdo da via, como está na figura 5.




Figura 5- Sinais de prescrição específica: a) Sinais de seleção de vias – E1 a E3. b) Sinais de afetação de vias – F1 e F2. c) Sinais de zona - G1 a G9.

Nesta seção serão destacados alguns trabalhos e artigos anteriores sobre o reconhecimento de sinais de trânsito, os quais constituem um exemplo do estado da arte das pesquisas realizadas na área.

Alguns destes trabalhos apresentados nesta seção mencionam a utilização dos modelos de cores RGB (*red, green, blue* – vermelho, verde, azul); HSI (*hue, saturation, intensity* – cor, saturação, intensidade) e HSV (*hue, saturation, value* – cor, saturação, valor). Para este estudo, alguns destes modelos serão apresentados nas seções posteriores desta Dissertação.

2.2. Modelos de Cor

No enquadramento desta seção, falaremos de espaços de modelos de cor para imagens digitais, com mais destaque os modelos RGB e HSV.

No modelo de cores RGB, cada uma das cores é representada de acordo com os valores de seus respectivos componentes espectrais. Isto quer dizer que os componentes espectrais de uma cor correspondem a valores para o vermelho, verde e azul. Dessa forma, a representação das cores no modelo RGB baseia-se em um sistema de coordenadas cartesiano tridimensional (3-D). Por conveniência assume-se que todos os valores de cores foram normalizados, para que as magnitudes das componentes RGB estejam no intervalo $[0,1]$. Vários autores apresentam de forma resumida o espaço RGB através de um cubo, (Figura 6) com valores das três componentes de uma imagem de 8 bits. Assim cada componente corresponde um eixo do espaço tridimensional, sendo as coordenadas dos vértices que interseccionam os eixos os valores RGB, enquanto que as coordenadas do cubo que interseccionam os planos RB, BG e RG pertencem às cores secundárias (Cyan Magenta Yellow) Gonzalez & Woods (1993). Figura 7.




Figura 6- Cubo do Modelo RGB.



Figura 7- Misturas de cores do modelo RGB.

O modelo de cores RGB é um modelo aditivo baseado na teoria de visão colorida tricomática e no triângulo de cores. O nome do modelo e abreviatura RGB vêm das três cores primitivas: vermelha, verde e azul, e só foi possível devido ao desenvolvimento tecnológico de tubos de raios catódicos com os quais foi possível fazer o display de cores ao invés de uma fosforescência. As três cores não podem ser confundidas com os pigmentos primários ciano, magenta e amarelo, conhecidos no mundo das artes como cores primárias do modelo subtrativo CMY. O modelo RGB, por si só, não define o que significa “vermelho”, “verde” ou “azul”, e então os resultados de misturá-los não são tão exatos (e sim relativos, na média da percepção do olho humano).

Uma cor no modelo de cores RGB pode ser descrita pela indicação da quantidade de vermelho, verde e azul que contém. Cada uma das cores que compõe o modelo RGB pode variar entre o mínimo (completamente escuro) e máximo, o resultado é preto. Se

todas estão no máximo, o resultado é branco. Uma das representações mais usuais para as cores é a utilização da escala 0 a 255, bastante encontrada na computação pela conveniência de se guardar cada valor de cor em 1 byte (8 bits). As cores primárias, secundárias, branca e preta representam-se da seguinte forma no modelo RGB 8 bits:

- Branco – RGB (255, 255, 255)
- Azul – RGB (0, 0, 255)
- Vermelho – RGB (255, 0, 0)
- Verde – RGB (0, 255, 0)
- Amarelo – RGB (255, 255, 0)
- Magenta – RGB (255, 0, 255)
- Ciano – RGB (0, 255, 255)
- Preto – RGB (0, 0, 0)

As cores secundárias do modelo RGB são Ciano (Cyan), Magenta (Magenta) e Amarela (Yellow), que são as cores primárias do modelo subtrativo CMY.

Gonzalez & Woods (1993), apresenta uma desvantagem inerente ao processamento de imagens através da utilização do modelo de cores RGB; baseado na dificuldade em se lidar com a iluminação da imagem. Se precisamos de processar informações de uma imagem, e parte da mesma encontra-se mal iluminada ou simplesmente com iluminação diferente do restante, torna-se muito difícil compensar as diferenças para que a imagem seja processada adequadamente. Existem algumas abordagens que tentam minimizar esse problema, mas a melhor abordagem é a utilização de um modelo de cores que, ofereça melhores condições de lidar com a iluminação de uma imagem. Um dos modelos de cores capaz de oferecer tal facilidade é o modelo HSV, que será apresentado no próximo parágrafo.

O modelo de cor HSV (*Hue Saturation Value / Intensity – Cor Saturação Valor / Intensidade*) descreve as cores da forma alternativa ao modelo RGB. O parâmetro *Hue* descreve as cores puras, *Saturation* mede o grau em que uma cor pura é diluída pela luz branca e *Value/Valor* está relacionado com a noção da luminosidade de uma cor que não pode ser diretamente quantificado. O modelo possui o apelo intuitivo das designações da matriz (análoga à cor), sombra (análoga à saturação) e tonalidade (análoga ao valor), provenientes da manipulação de cores Foley *et al.* (1997).




Figura 8- Modelo de cor de HSV: a) representado com hexacone (Foley 1997); b1) como cone e b2) vista de um segmento do cone HSV- (Pierce, 2004).

O sistema de coordenadas usado no modelo de cores HSV é cilíndrico. Utilizando como referência a imagem (b1) da figura 8, vemos que a componente H assume valores angulares no sistema de coordenadas cilíndrico (no intervalo $[0; 360]$), a componente S assume valores lineares ao longo do raio do cone (no intervalo $[0, 1]$), e a componente V com valores lineares ao longo do eixo do cone (no intervalo $[0,1]$). No vértice do cone, o valor (V) é igual a zero (o que representa a cor preta); na base do cone, onde estão as cores com maior luminosidade, $V=1$ (para $S=0$, temos a cor branca). No entanto, no plano onde o $V=1$, as cores não possuem necessariamente a mesma luminosidade, ao longo do eixo do cone situam-se os tons de cinza Foley *et al.* (1995).

A cor (H) é definida por um valor angular (Figura 8 a)): um ângulo igual a zero corresponde à cor vermelha; um ângulo de 120° corresponde à cor verde, e assim por diante. Quando a saturação (S) vale zero, o valor da cor (H) torna-se irrelevante, sendo tratado como “indefinido”. Porém quando S é maior do que zero, H torna-se relevante. Quando $V=1$ e $S=1$, todos os valores angulares assumidos por H corresponderão as cores puras (por exemplo, se temos $V=1$, $S=1$ e $H=0$, temos o vermelho puro). Esse fato é análogo ao pigmento puro das tintas, utilizado pelos artistas como ponto inicial para a mistura das cores Foley *et al.* (1997).

Por utilizar uma maneira para representar as cores baseada na percepção humana, e também por fornecer os componentes para a cor (H) que não depende das magnitudes da saturação (S) e de valor (V) (mesmo quando o valor de (H) torna-se “indefinido”, ainda sim ele permanece independente), o modelo de cores HSV é mais adequado do que o RGB quando o processamento de imagens envolve algum passo fundamental, necessitando que os objetos sejam encontrados na imagem através das suas cores. Isso significa dizer que a cor (H) dos objetos de uma imagem é invariante às mudanças de luz presentes nessa imagem (que, por sua vez, são definidas por S e por V), o que facilita que uma área de

determinada cor seja identificada na imagem, independentemente das condições de iluminação na superfície dessa área Fang *et al.* (2003).

2.3. Segmentação e Binarização

Para o processamento de imagem ocorrer, devem ser seguidos alguns passos fundamentais, os mesmos aparecem no livro de Gonzalez & Woods (1993) esquematizado de seguinte:

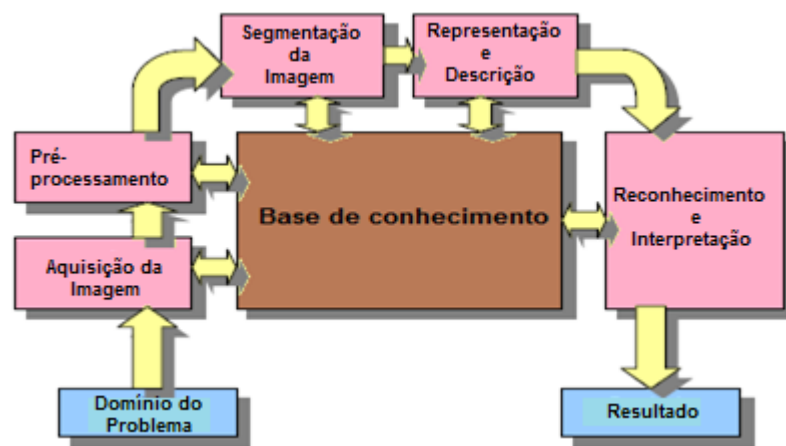


Figura 9- Passos Fundamentais em Processamento de Imagens digitais.

- **Aquisição da imagem** – nesta fase, podemos utilizar uma câmara de vídeo, fotográfica ou digitalizador de imagens (*scanner*);
- **Pré-processamento** – com o objetivo de melhorar a imagem de maneira que o resultado desse processamento auxilie na resolução do problema para os processos subsequentes;
- **Segmentação** – partição da imagem em unidades mais significativas, ou extração das áreas que interessam para a resolução do problema;
- **Representação e descrição** – representa os dados como regiões completas ou fronteiras e descreve características das áreas apresentadas que deverão ser convertidas em conjunto de informação quantitativa de interesse para resolução do problema;
- **Reconhecimento e Interpretação** – reconhece o objeto de acordo com as informações das suas características e atribuição de um significado ao objeto reconhecido;

- **Base de conhecimento** – O domínio do problema está codificado sob o conhecimento em um sistema de processamento de imagens na forma de uma base de conhecimento.

Em conexão com os seis passos indicados, deve existir uma base de conhecimentos. Essa base é o que dá sentido ao processamento da imagem, uma vez que essa base contém informações importantes que podem estar contidas na base de conhecimentos, tais como: conhecimento prévio dos locais onde a informação desejada poderá estar; ou listas de itens a serem procurados na imagem.

Em processamento de imagem, a segmentação é o processo de subdivisão de uma imagem em regiões (segmentos), ou ainda, consiste em identificar e extrair zonas homogêneas presentes numa imagem. Cada pixel da imagem pertence necessária e unicamente a uma das regiões da imagem. A segmentação usada para a detecção dos sinais de trânsito é a segmentação por cor. Como os sinais de trânsito majoritariamente possuem as suas bordas azuis e vermelhas, um sistema que visa detetar sinais de trânsito deverá em primeiro lugar efetuar uma segmentação destas duas cores.

Este espaço cor, apesar de ser usado no mundo da computação, apresenta algumas desvantagens relativamente ao processamento digital de imagem. A principal desvantagem que consiste neste espaço cor ser muito sensível às variações de luminosidade. De modo a ultrapassar a dificuldade da heterogeneidade de efeitos originados pela iluminação, realiza-se uma alteração de espaço cor, passando-se assim trabalhar no espaço cor HSV. Neste espaço de cor os efeitos resultantes de diferentes condições de iluminação são mais facilmente minimizados e previsíveis do que no espaço cor RGB (Sousa, 2005).

A binarização de uma imagem é um processo que consiste na alteração das propriedades da cor que uma imagem possui. Partindo de uma imagem colorida, é efetuado um processamento tendo em conta uma imagem de interesse que tornará a imagem em duas cores (preto e branco). Com isto, cada pixel apenas toma dois valores possíveis: “um” para a zona pretendida e “zero” para o fundo da imagem. No que diz respeito a um sistema de detecção e reconhecimento de sinais de trânsito, a utilização de uma imagem binária revela-se bastante na medida em que é possível isolar completamente o sinal de cor pretendido de todos os outros objetos presentes na imagem, possibilitando que as técnicas a serem impostas apenas sejam aplicadas em zonas cujos pixels possuam valor “um”.

No caso do modelo usado para a segmentação da imagem (o modelo HSV), cada pixel é composto por três componentes: tonalidade, saturação e intensidade. Para uma

eficaz binarização, o valor de cada pixel é analisado para verificar se a cor representada por ele é vermelha ou azul. Se a cor apresentada estiver na gama de valores correspondente a uma destas duas cores, com a respetiva saturação e intensidade desejadas, esse pixel tornar-se-á branco. Caso contrário, será preto. O resultado será uma imagem a preto e branco, de apenas um canal.

Uma das formas mais simples e mais utilizadas na segmentação de uma imagem digital consiste na partição do histograma em duas ou mais partes, utilizando-se um ou mais valores de corte T_i , nas intensidades. Todos os pixels da imagem são tratados da mesma forma, dependendo apenas do seu nível de cinzento (*'Thresholding'* Global) Gonzalez & Woods (2002).

Em algumas aplicações é muito necessário processar apenas uma determinada área com vista a reduzir o tempo de processamento. Pois que a criação de uma região de interesse, vulgarmente conhecida por ROI (*region of interest*), revela-se de extrema importância quando inserido num sistema que atua em tempo real. Quando o sinal de trânsito é detetado, são obtidas as suas coordenadas através de uma imagem principal e é criada uma nova imagem onde este surgirá. Ao implementar qualquer função de processamento de imagem da biblioteca, a função verifica a existência de algum ROI definido na estrutura de dados da imagem. Caso exista, o processamento irá incidir apenas na região definida pelo ROI. A função disponível na biblioteca, permite a criação de um ROI, cujos seus parâmetros definem a localização e o tamanho da nova imagem (Alves, 2004).

2.4. Sistemas de Detecção e Reconhecimento de Sinais de Trânsito

Durante a revisão bibliográfica feita no desenvolvimento deste trabalho, constatamos que nos últimos anos houve um aumento de número de artigos sobre deteção e reconhecimento de sinais de trânsito. Os artigos aqui referenciados são apresentados de forma cronológica dos anos em que foram publicados.

Azami *et al.* (1996) apresentam um sistema de deteção e reconhecimento de sinais informativos de forma retangular. Na fase de deteção são utilizados três módulos que funcionam em paralelo, em que cada um é responsável por encontrar objetos com propriedades distintas: objetos retangulares (através da extração de arestas), rodeados por outras cores semelhantes, tais como céu, objetos de cores verde e/ou azul, (com base no valor do *Hue*, no espaço de cor HSV). Na fase de reconhecimento, o conteúdo dos sinais que consiste em setas, caracteres chineses e/ou números romanos é modelado através da

deteção e posterior a extração de cada um dos retângulos que circunscrevem os símbolos existentes. A identificação dos caracteres é feita através da correspondência linha a linha com vários modelos de caracteres existentes numa base de dados. O reconhecimento das setas é conseguido com recurso à topologia das mesmas que é comparada com a topologia de vários modelos pré-definidos.

Picciolo *et al* (1996) descrevem um método para detetar e reconhecer a região adequada da imagem com base no conhecimento à priori da localização do sinal ou da segmentação, fazendo uma análise geométrica das arestas de contornos, são extraídas a partir da imagem e depois o reconhecimento da fase de testes através de técnicas de correlação cruzada para cada candidato. Em seguida, através da aplicação do algoritmo *Canny*, é efetuada uma análise geométrica com o objetivo de verificar a presença de triângulos ou círculos através da deteção de bordas. Como resultados, para uma análise de 600 imagens contendo um ou mais sinais triangulares, a percentagem correta de deteção é de 92%. A forma ortogonal do sinal de STOP é identificada como uma forma circular, sendo apenas a diferenciação feita na parte do reconhecimento, onde é aplicado o método de "*Template Matching*". Desta forma o autor atinge uma taxa de classificação correta de 98%, apesar de não mencionar o número de sinais testados.

De la Escalera *et al* (1997) afirmam que as imagens são segmentadas para o vermelho, no espaço de cor RGB. Os objetos candidatos a sinais, resultantes da fase de segmentação, são detetados pela sua forma através da aplicação de um método de deteção de contornos que resulta da convolução da imagem com filtros específicos de correlação. A classificação dos sinais (após da normalização das imagens) é feita com recurso das redes neuronais do tipo perceção multicamada, em que o input corresponde ao sinal detetado. Utilizam como objetos de estudos 18 tipos de sinais distintos (9 sinais circulares e 9 sinais triangulares), mas a fase experimental é pouco clara.

Hsu & Huang (2001) descrevem um sistema de reconhecimento automático de sinal de trânsito usando filtros de perseguição correspondente (MP) Matching Pursuit, em duas fases. Na fase de deteção, procura encontrar a posição relativa distante da imagem original na estrada, o reconhecimento provem da dedução, dando informação da forma e cor e captar uma imagem de visão mais próxima e extrai a imagem de sinal a partir da imagem mais próxima usando o modelo de correspondência convencional "*Template Matching*". A fase de reconhecimento consiste em dois processos: Treino e testes. No processo de treino encontra-se o melhor das bases dos filtros para cada sinal. O teste projeta a entrada do sinal desconhecido para um conjunto diferente de bases dos filtros MP para achar a melhor

correspondência. Na experimentação foram reconhecidos 94% dos 331 sinais triangulares de 30 tipos diferentes testados e 91% dos 118 sinais circulares de 10 tipos distintos.

De la Escalera *et al* (2002) procuram lidar com reconhecimento de objetos em ambientes ao ar livre. Neste tipo de ambientes as condições de iluminação não podem ser controladas e previsíveis, pois os objetos podem ser parcialmente obstruídos e sua posição e orientação não é conhecida a priori. O tipo de objetos escolhidos é sinais de trânsito ou de estrada, conforme a sua utilidade para a manutenção de sinal, inventário em rodovias e cidades, sistema de suporte ao condutor. Um algoritmo genético é utilizado para a etapa de detecção, permitindo que uma localização invariável (invariance localization) altere de posição, escala, rotação, condições climáticas, oclusão parcial, e a presença de outros objetos da mesma cor. Uma rede neuronal permite atingir a classificação. O sistema global não só reconhece o sinal de trânsito, como também fornece informações sobre a sua condição ou estado do sinal.

O Grego Hatzidimos (2004) descreve um sistema automático de reconhecimento de sinais de trânsito. Para a detecção o autor procede a segmentação de cor, depois obter imagem binária onde posteriormente serão detetados os contornos e normalizar os pixels de espessura. Para verificar o sinal triangular, aplica um método para analisar os ângulos de todas as linhas presentes na imagem. Caso estes não pertençam aos intervalos (50, 70) (-70,50) então é aplicada a transformada de “*Hough*” que deteta os sinais circulares. No reconhecimento implementa o modelo *Cross-Correlation Matching*, onde cada pixel é sujeito ao calcular o coeficiente de correlação cruzada nas três componentes do modelo RGB e o coeficiente final é a média das três componentes. Nas conclusões, relata que o sistema é muito eficaz na localização dos sinais de trânsito, mas possui uma ligeira fraqueza aquando da presença de áreas com a mesma cor dos sinais de trânsito. Admite um futuro reconhecimento e identificação de dois sinais numa mesma imagem. Por fim, o modelo RGB não é o melhor para efetuar a segmentação pois as três componentes dependem da intensidade e sugere para tal o modelo de cor HSI.

Shneier (2005) dos Estados Unidos de América (Gaithersburg), trata do reconhecimento de sinais de trânsito em tempo real. No seu sistema está implementada a técnica de segmentação por cor para identificar os sinais de trânsito presentes nas imagens captadas, em seguida, a imagem segmentada é binarizada. Nesta é aplicada uma erosão morfológica para eliminar pixels isolados que se tornam indesejáveis no que diz respeito à obtenção de sinais de trânsito. Para proceder ao reconhecimento, o autor usa o método de “*Template Matching*”. As imagens são retiradas do vídeo e são redimensionadas para o tamanho 48x48 pixels. A colocação em prática deste algoritmo contou com a análise de

23637 frames, contendo estes 92 sinais de perigo e STOP. Como resultados, o sistema apresenta para um total de 92 sinais analisados, uma percentagem de 88% de correta detecção, 78% de taxa de sinais bem reconhecidos, 58% de falsas detecções e um conjunto de 6 sinais com mau reconhecimento. O autor acredita que uma câmara apontada exclusivamente para a zona onde possam surgir bem como uma ampliação da imagem melhorava os resultados obtidos.

Andrey *et al* (2006) propõem uma detecção e reconhecimento do algoritmo para restrição, alerta e informa os sinais de estrada. A detecção é baseada na análise de cor e o reconhecimento é baseado na análise de forma. O processo de reconhecimento de sinais de informação e de proibição consiste em duas etapas. Extrair o sinal candidato da imagem e classificar o sinal como sendo um círculo ou um triângulo usando o histograma. Em seguida converter o interior do sinal em uma máscara binária e aplicar um algoritmo de correspondência de modelo. Para entender o significado do sinal de informações, separa-se a imagem em componentes básicos: setas e texto e, em seguida, analisa-se o relacionamento posicional entre esses segmentos. A detecção das pontas das setas é baseada em operações morfológicas e análise de características especiais como a área e a direção. O resultado de reconhecimento é o nome do sinal para sinais de aviso e proibição e um conjunto de direção de pares de lugar de sinais de informação.

Yehua *et al* (2008) trazem como proposta um novo algoritmo para a detecção do sinal de trânsito e reconhecimento baseado em características e redes neurais probabilísticas. Em primeiro lugar, as características de cor globais da imagem são calculadas com base na teoria de estatísticas. Em segundo lugar, a projeção da quantidade de cinza (Gray-Value) e análise de formas são usados para confirmar regiões de sinal. Em terceiro lugar, a segmentação de imagens auto adaptativa é usada para extrair formas binárias no interior que é calculado pela transformação de projeção central. Em quarto lugar, estes vetores são entradas das treinadas redes neurais probabilísticas para o reconhecimento de sinais de trânsito. Por último, são comparados os resultados de reconhecimento na imagem da esquerda com os da direita. Se resultar em imagens idênticas, estes resultados são confirmados como resultados de reconhecimento finais. O novo algoritmo é aplicado às 220 imagens reais obtidas por um veículo móvel de um sistema de fotogrametria em movimentos diferentes. Os resultados experimentais mostram uma taxa de detecção e reconhecimento de mais de 92%. Assim, o algoritmo é fiável e de alta velocidade na detecção e reconhecimento do sinal de trânsito em tempo real.

Gil-Jiménez *et al* (2008) citado por Isabel Gonçalves (2009), indica algumas possíveis aplicações de sistemas de detecção e reconhecimento, tais como a integração

dos mesmos nos veículos automóveis inteligentes, em sistema de assistência à condução em que uma das funcionalidades consistiria na limitação da velocidade do veículo; na manutenção da infraestruturas rodoviárias, incluindo os sinais de trânsito, que pode ser automatizada através de sistemas de deteção e reconhecimento dos mesmos, ao invés de ser efetuada manualmente com recurso a operadores que visualizam sequências de vídeo obtidas através de sistemas móveis de levantamento.

Fleyeh & Dougherty (2008) implementaram um algoritmo cujo objetivo consiste em detetar e reconhecer sinais de trânsito. A deteção dos demais sinais de trânsito presentes na via, é usada a segmentação por cor. Os autores referem que o modelo de cor obtido através da câmara não é adequado para a deteção na medida em que as três componentes do modelo estão altamente correlacionadas entre si, resultando que qualquer variação na intensidade de luz do ambiente afetará todo o modelo, acabando por surgir outros modelos de cor tais como HSI, HSB, L^*a^*b , YIQ, YUV. Após a deteção de objetos cujas cores respeitam os valores de *threshold* pretendidos, os candidatos a sinais são sujeitos a um algoritmo de reconhecimento que, segundo os autores, deverá possuir um grande poder discriminatório e uma forte resistência a ruído e a diferentes posições do sinal. Como alternativa à classificação e reconhecimento surgem no uso das redes neuronais defendendo que assim não será necessário a conversão da imagem para um novo modelo de cor, que o resultado da classificação só depende da correspondência de padrão serão evitados. Contudo, as redes neuronais necessitam de uma sobrecarga de treino e o uso de multicamadas que é limitado à aplicação em tempo real dado que a sua arquitetura é fixa, não havendo uma previsão de um aumento do número de classes sem uma penalidade acentuada.

Souki *et al.* (2008) descrevem um sistema de visão computacional que permite o reconhecimento de sinais de trânsito em tempo real. Os autores aplicam sobre a imagem captada pela câmara um filtro médio que permite a redução do ruído. Este filtro, segundo os autores, é mais simples em comparação com o filtro da mediana que normalmente é utilizado. Posteriormente, para a deteção dos sinais de trânsito na imagem filtrada é aplicada a técnica de segmentação da cor vermelha no modelo de cor RGB. É efetuada a binarização da imagem e aplicado um novo filtro, neste caso, um filtro de bordas que se revela, garantem os autores, menos complexo que os filtros *Canny* e *Sobel*. Para proceder a deteção de círculos, o sistema possui implementado a transformada de *Hough*. O sinal é retirado da imagem (região de interesse) e normalizado para o tamanho de 80x80 pixels. É aplicado um filtro mediano para reduzir o ruído e informações redundantes antes do estágio de binarização. Por último, é aplicado o método “*Cross Correlation*” para determinar a semelhança entre duas imagens. O autor apresenta ainda uma tabela onde compara o

tempo de processamento das diversas fases do seu sistema, sendo a transformada de *Hough* a que despende mais tempo, tendo cerca de 72% do tempo total.

Gonçalves (2009) sugere uma técnica para o reconhecimento e classificação de sinais previamente identificados em imagens digitais de vídeo recolhidas através de um sistema móvel de levantamento (MMS). A metodologia desenvolvida consiste em extrair as características dos sinais, a partir dos histogramas das componentes vermelha, preta e azul da imagem original, após esta ter sido convertida no espaço HSI. A posterior classificação supervisionada das imagens é feita com recurso aos seguintes classificadores: distância euclidiana, distância absoluta, distância de Mahalanobis e o método dos k vizinhos mais próximos. A precisão média obtida no caso dos cenários com a distância euclidiana é de 94,9%. Caso sejam considerados os dois melhores resultados, ou os três melhores, a precisão média atinge os 98.7% e os 99.4%, respetivamente.

Sampaio (2010) desenvolveu um algoritmo para a deteção e reconhecimento automático de sinais de trânsito em tempo real, bem como em fotografias e vídeos previamente gravados. Para a deteção dos sinais de trânsito é efetuada uma análise à cor presente na imagem, nomeadamente, é posta em prática a técnica de segmentação da cor vermelha, preta e azul. Os sinais detetados são sujeitos a um conjunto de técnicas e métodos que permitem classificar os sinais de acordo com a sua forma, podendo ser formas triangulares, circulares, quadradas ou octogonais. Com o objetivo de facilitar o reconhecimento dos sinais detetados, o sistema permite a sua classificação em cinco classes, conforme a combinação entre a sua cor e forma. Para o reconhecimento, a figura padrão que distingue os demais sinais de trânsito é analisada, com vista à obtenção da posição exata bem como a área que esta ocupa. Por fim, é implementado o método de correlação de fase que permite verificar a semelhança entre duas imagens. Esta comparação é efetuada através dos sinais adequados pela câmara e os sinais presentes numa base de dados.

Correia (2010) faz um estudo que reside no desenvolvimento de um sistema embutido de reduzida capacidade computacional e baixo consumo energético. O sistema constituído por um processador NXP LPC2106 (NXP, 2008) com arquitetura ARM7, destina-se à obtenção e processamento de imagens, com o intuito de detetar e reconhecer sinais de trânsito portugueses. Face ao processador utilizado e às características almejadas para o sistema embutido, foi criado um conjunto de algoritmos que requerem reduzidos recursos computacionais e maioritariamente constituído de raiz permitindo um profundo conhecimento do funcionamento destes algoritmos. Cada algoritmo foi testado com imagens estáticas, primeiramente utilizando o MATLAB e posteriormente através da

programação da CMUcam3. Foi também efetuada a simulação do ambiente de estrada e finalmente foram realizados testes práticos. As limitações impostas pelo dispositivo levaram ao aumento da complexidade do projeto, porém, o resultado final corresponde a uma taxa de reconhecimento de 81,9%. Neste sentido, pode-se considerar que a taxa de reconhecimento conseguida ultrapassou as expectativas perspetivadas para o sistema embutido.

De Sousa (2005) citado por Sampaio (2010) faz a deteção e reconhecimento de sinais de trânsito, onde na deteção usou duas metodologias, a primeira, o sinal é selecionado pelo utilizador e na segunda, através da informação da cor e do seu contorno. A classificação dos sinais foi feita quanto à sua forma pré-definida: quadrado, círculo, triângulo e o triângulo invertido, as assinaturas de contorno (radiais) confundiram por 7 vezes, num total de 234 sinais, a forma quadrangular com a forma circular. E comparou com três classificadores distintos: Coeficiente de correlação, média aritmética dos valores absolutos das diferenças entre contornos e média aritmética dos desvios absolutos dos pontos de contornos a partir da sua média. O reconhecimento dos sinais, é obtido através do método da correlação normalizada de níveis de cinzento. A base de dados possui 38 sinais em níveis de cinza, normalizados para 64x64 pixéis. Na análise de 234 sinais, foram eliminados pelo classificador 12 sinais erradamente e a forma foi confundida num total de 7 vezes. Restando 215 sinais corretamente classificados quanto à sua forma, o seu reconhecimento obteve uma taxa de precisão que rondou os 83%.

Fatin & Bogdam (2012) afirmam que o reconhecimento de sinais de trânsito (Traffic Signs Recognition - TSR) é um componente importante de sistemas avançados de condução assistida (Advanced Driver Assistance Systems - ADAS). No artigo deles, apresentam sistema de reconhecimento de sinalização de trânsito de três fases em tempo-real, que consiste em uma segmentação, a deteção e a classificação. A segmentação é para extrair regiões da imagem. A deteção é realizada utilizando uma eficiente máquina de suporte vetorial (SVM) com características lineares de histogramas de gradientes orientados (HOG). Os classificadores de árvores, K-d árvore e floresta aleatória, identificam o conteúdo dos sinais de trânsito encontrados. Propõem para melhorar o desempenho da K-d árvore. A floresta aleatória (Random Florest) e o critério de Fisher são usados para reduzir o recurso de espaço e acelerar a classificação. Mostraram que apenas um subconjunto de 18 - 28 classes onde atingiram um reconhecimento com uma taxa de classificação de cerca de 81% sobre o German Traffic Sign Recognition Benchmark (GTSRB).

Da Silva *et al.* (2013) ressaltam a importância dos sinais de trânsito, que estabelecem as regras de navegação pelas vias, por terem propriedades visuais muito fortes, pois foram projetados para serem objetos facilmente identificáveis. O reconhecimento de sinais de trânsito permite que um motorista possa ser avisado sobre ações impróprias e potencialmente perigosas. No artigo eles propõem uma metodologia para o reconhecimento de sinais de trânsito utilizando imagens capturadas por um sistema de mapeamento móvel. A abordagem proposta aplica o algoritmo SIFT (Scale Invariant Feature Transform) para extrair recursos de pontos-chave, usados para avaliar a correspondência entre uma imagem de estrada contendo uma ou mais placas e as imagens de alguns sinais de trânsito (modelos). Finalmente, para filtrar somente os pares de pontos-chave (modelo de imagem) que são compatíveis, bem como a orientação e o posicionamento, propõem um novo algoritmo que usa essa informação.

Dos Santos (2013) faz um estudo e desenvolve um método de reconhecimento automático de sinalização vertical de trânsito (RASVT), onde a metodologia desenvolvida de reconhecimento de sinalização vertical de trânsito funciona com modo pós-aquisição, processando os dados de vídeo em bruto (raw) e os dados de posicionamento. O método desenvolvido possui três fases: A detecção, classificação e reconhecimento. Utilizando a correlação simples na correspondência realizada. A fase de detecção apresentou uma taxa de sucesso de 32% (que excluindo os resultados falsos positivos, apresenta uma taxa de sucesso de 89%), a fase de classificação teve uma taxa de sucesso de 93% a fase de reconhecimento teve uma taxa de sucesso de 91%. A taxa de sucesso global obtido pelo método RASVT implementado é de 81%, ou seja, da sinalização presente na amostra analisada, 81% foi corretamente detectada, classificada e reconhecida.

Phalguni *et al.* (2013) discutem o design do processador de implementação de um sistema que detecta e reconhece os sinais de trânsito presentes em uma imagem. Os autores aplicaram cinco métodos: o momento de correspondência, histograma de correspondente base, histograma de correspondente de gradientes bases, distância euclidiana de correspondência de base e correspondência de modelos são usados para reconhecer o sinal de trânsito no ROI. Um sistema de classificação baseado na forma do sinal é adotado no desempenho dos vários métodos de reconhecimento é avaliada ao comparar o número de ciclos de relógio usados para executar o algoritmo no processador. A utilização de vários métodos para reconhecer os sinais de trânsito permite a personalização com base no desempenho dos métodos para diferentes conjuntos de dados. As experiências mostram que o sistema desenvolvido é robusto e bem adequado para aplicações em tempo real e que alcançou reconhecimento e classificação com exatidão até 90%.

Yishan *et al.* (2015) focalizam-se numa investigação e implementação de um sistema de reconhecimento de sinal de trânsito. A identificação e reconhecimento de sinal de trânsito rodoviário, como um sistema de transporte inteligente, desempenham um papel cada vez mais importante para a segurança rodoviária. Neste trabalho, é apresentado um método robusto e em tempo real para identificar e detetar os sinais de velocidade numa imagem da estrada. Em primeiro lugar, a identificação do processamento de imagem e sinais de trânsito rodoviário está na base de uma priorização da informação sobre a forma. Identificação de bordas ou contornos e métodos de morfologia matemática que criam componentes de conectividade. Em segundo lugar, o RGB e o HSV conversão de espaço de cores são usados no processamento de imagem.

Selcan, et al. (2016) trazem como propostas novas abordagens para a deteção e reconhecimento de imagens coloridas. Na deteção de sinais de trânsito, é proposta a nova abordagem de que utiliza um algoritmo de deteção do círculo recentemente desenvolvido e uma técnica de coloração de limiar com base em RGB. No reconhecimento de sinais de trânsito, existem um conjunto de recursos, incluindo histogramas de gradientes orientados, padrões binários locais e características Gabor são empregados dentro de uma estrutura de máquina de classificação de vetores de suporte. As performances das abordagens de deteção e reconhecimento propostas são avaliadas em sinais de trânsito Alemão de deteção e reconhecimento conjuntos de dados de referência, respetivamente. Os resultados do trabalho experimental revelaram que ambas as abordagens oferecem desempenhos comparáveis ou mesmo melhores no que diz respeito aos melhores relatados na literatura e são compatíveis para operação em tempo real.

Ayoub *et al.* (2016) apresentaram uma nova deteção de sinal de trânsito e método de reconhecimento (TSDR), o que é conseguido em três etapas principais. O primeiro passo, segmenta a imagem com base no limiar de componentes de espaço de cores HSI. O segundo passo deteta sinais de trânsito através do processamento dos pixéis extraídos pelo primeiro passo. O último passo, executa o reconhecimento dos sinais de trânsito detetados. As principais contribuições deste artigo são as seguintes: em primeiro lugar, propõe que no segundo passo se usem invariantes geométricas para classificar as formas em vez de algoritmos de aprendizagem automática. Em segundo lugar, inspirados pelos recursos existentes, novos recursos têm sido propostos para o reconhecimento. O histograma de gradientes orientados (HOG) foi um recurso que foi estendendo para o espaço de cor HSI e combinadas com a Auto similaridade local (LSS) para obter o descritor que usaram no algoritmo. O método proposto foi testado em sinais de trânsito Alemão e nos sinais Suecos. Os resultados obtidos são satisfatórios quando comparados com os métodos da última geração.

Capítulo 3- Metodologia

3.1. Disposição dos Elementos Metodológicos

O objetivo primordial deste trabalho baseia-se num estudo das técnicas usadas no reconhecimento de imagens, assim como um estudo de algoritmo de reconhecimento de imagens. A implementação consiste na aquisição de imagens de sinalização rodoviária de uma base de dados através de técnicas de reconhecimento de imagens, usando o *software* computacional MATLAB R2016a *Student Version*. Para ocorrer esta implementação, foram necessários alguns passos básicos que descrevem melhor os algoritmos deste operador. O primeiro passo é o processo de aquisição das imagens na base de dados fornecida, para em seguida trabalhar com elas no ambiente computacional MATLAB. Os principais passos da metodologia usada estão esquematizados de forma simplificada nos fluxogramas apresentados nas figuras 10 e 11.

Esquema do processo de classificação.

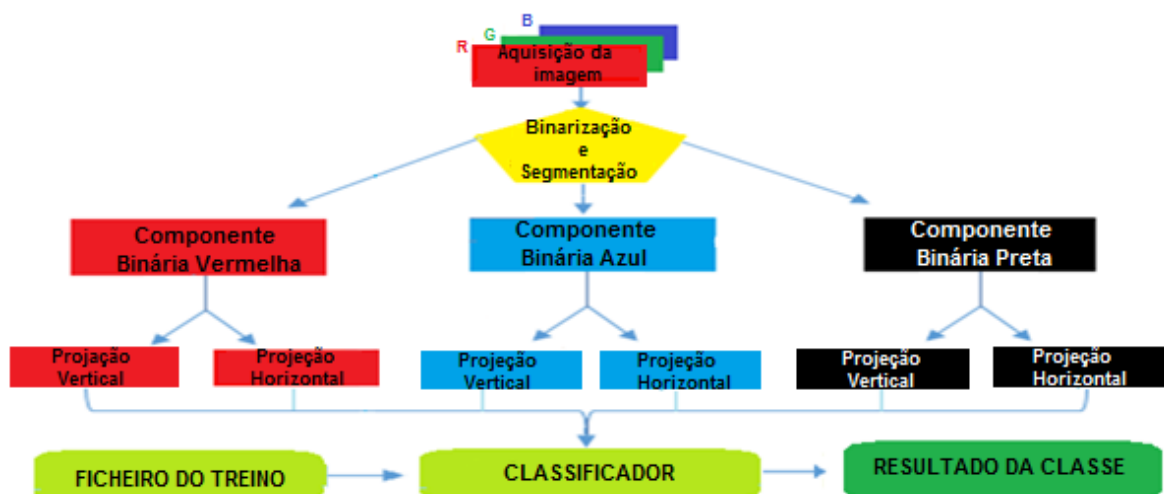


Figura 10- Esquema da metodologia da classificação.

A figura 10 apresenta um esquema do processo de classificação, que é composto das seguintes fases:

- **Aquisição da imagem:** as imagens são localizadas nas bases de dados fornecida (GTSRB) e FCUP, entrada da imagem a cor (RGB) e importados para memória (no MATLAB).
- **Binarização e segmentação:** converte a imagem RGB para binária e depois segmentar a imagem binária.

- **Componente binária vermelha:** separa a componente binária vermelha.
- **Componente binária azul:** separa a componente binária azul.
- **Componente binária preta:** separa a componente binária preta.
- **Projeções vertical e horizontal:** em cada componente binária são extraídas as duas projeções, fazendo um total de seis projeções.
- **Ficheiro de treino:** matriz inscrita na fase de treino.
- **Classificador:** recebe as projeções e o ficheiro de treino, classifica e fornece o resultado da classe da imagem.

A figura 11 apresenta um esquema do processo de treino. É um ciclo repetitivo do processo anterior com um número de execuções igual à quantidade de exemplares usados para treino. No final são atualizados os resultados dos cálculos de projeções médias por cada classe da base de dados fornecida. Esta atualização é feita por uma metodologia da fase de treino, que por nossa escolha determinamos o número de imagens por classe que usamos para essa fase. Feito isso, no final exporta os resultados para um ficheiro texto.

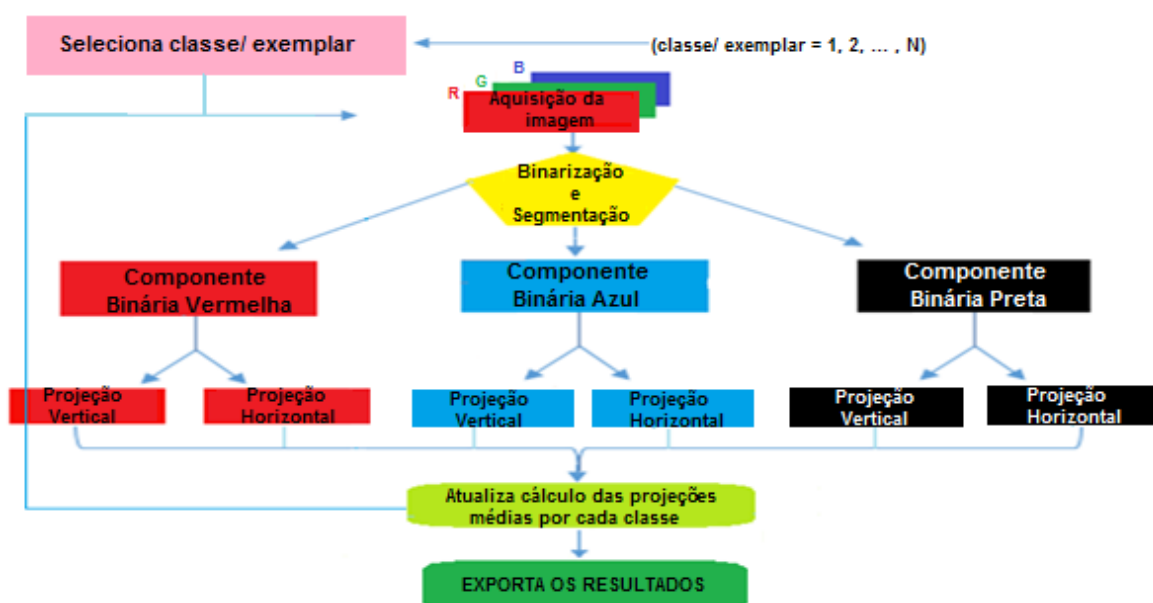


Figura 11- Esquema da metodologia da fase de treino.

3.2. Pré-processamento das Imagens

O software MATLAB considera as imagens como matrizes de dados e podem ter associados um mapa de cores. Neste caso existem quatro tipos de imagens que podem ser trabalhadas: de intensidade, indexadas, RGB e binárias. Para se construir uma imagem indexada são necessárias duas matrizes, a primeira contém um valor numérico como índice para a segunda matriz formada pelas quantidades das cores R (Red - Vermelha), G

(Green - Verde) e B (Blue - Azul) para o pixel correspondente. As de intensidade são formadas por matrizes de dados cujos valores representam as intensidades em cada ponto. As imagens RGB são compostas por três matrizes separadas para R, G e B, normalizadas. As binárias são aquelas na qual têm apenas dois valores possíveis para cada pixel, onde é feito um arranjo lógico de zeros e uns; onde o número “0” indica cor preta e o número “1” indica cor branca.

O reconhecimento de sinais de trânsito a partir de imagens a cores, baseia-se na extração de objetos vermelhos, azuis e pretos. Para tal, procede-se a segmentação de cada uma das componentes da imagem original, de modo a obter uma imagem binária, que contenha apenas os objetos com a cor pretendida. O processo de segmentação pode ser descrito por equações, onde a variável k designará uma dada componente associada ao modelo de cor utilizado, α_k e β_k são valores mínimo e máximo, respetivamente da componente k para aquela cor e $I_k(i, j)$ o pixel da linha i e coluna j da componente k da imagem original. Seja $B_k(i, j)$ o pixel que se encontra na linha i e coluna j da imagem binária resultante da segmentação da componente k ;

$$B_k(i, j) = \begin{cases} 1 & \text{se } \alpha_k \leq I_k(i, j) \leq \beta_k \\ 0 & \text{caso contrário} \end{cases} \quad (1)$$

Enquanto a matriz binária resultante do processo de segmentação contém apenas os objetos com a cor pretendida. Esta é obtida através da interseção das matrizes resultantes da binarização das diversas componentes do modelo de cor (β_k), (Gonçalves, 2009).

$$\beta = \bigcap_{k=1}^3 B_k \quad (2)$$

No modelo de cores RGB (*Red, Green, Blue* – Vermelho, Verde, Azul), cada uma das cores é representada de acordo com os valores de seus respetivos componentes espectrais, dando uma matriz e que representam uma única cor. Cada posição da matriz corresponde a um pixel da imagem, com a mesma localização. Sendo assim, o pixel que estiver na posição (i, j) terá associado a si três valores, um para cada componente do modelo RGB, dados por essa ordem. A cor do pixel (i, j) depende da combinação das três componentes desse modelo de cor. Caso a imagem seja de oito (8) bits, cada um dos elementos das três matrizes pode tomar valores entre 0 e 255, o que perfaz uma soma de

2^8 valores diferentes. Numa combinação das três componentes assim teremos a existência de $(2^8)^3 = 2^{24} = 16777216$ cores distintas Gonzalez *et al.* (2004).

Depois de obtermos as imagens das bases de dados que usaremos nesta fase, já que as mesmas reúnem os requisitos acima descritos, fizemos o uso do MATLAB e criamos algumas funções para podermos ter os resultados conforme a exigência das teorias em que nos baseamos.

Na Figura 12, um exemplo de um sinal na forma original (RGB), e as suas componentes R, G e B como imagens monocromáticas. É de realçar que a zona vermelha do sinal da componente R apresenta uma cor mais clara do que as componentes G e B. Destaca-se ainda diferença a mesma zona vermelha ser um pouco mais clara na componente G do que em B.



Figura 12- Exemplo de uma imagem RGB - a) e sua componentes R - b), G - c) e B - d).

Enquanto que o modelo de cor HSV (*Hue Saturation Value*), descreve as cores de uma maneira alternativa do modelo RGB. O parâmetro *Hue* descreve as cores puras, *Saturation* mede o grau em que uma cor pura é diluída pela luz branca e *Value* está diretamente relacionado com a noção de brilho de uma cor que não pode ser diretamente qualificado. A Figura 13 apresenta um exemplo de uma imagem RGB e as suas componentes H, S, V, depois da imagem ter sido convertida do modelo RGB para HSV.




Figura 13- Exemplo de uma imagem HSV - a) e sua componentes H - b), S - c) e V - d).

Segundo Gonzalez & Woods (1993), a conversão pode ser calculada a partir das seguintes equações; onde RGB corresponde as componentes vermelhas, verde e azul, de um dado número de pixel e H, S, V os componentes Hue, Saturation, Value.

$$H = \begin{cases} \theta \Leftarrow B \leq G \\ 360^\circ - \theta \Leftarrow B > G \end{cases}, \text{ com } \theta = \arccos \left(\frac{\frac{1}{2}[(R-G) + (R-B)]}{\sqrt{(R-G)^2 + (R-B)(G-B)}} \right) \quad (3)$$

$$S = 1 - \frac{3}{(R+G+B)} [\min(RGB)] \quad (4)$$

$$V = \frac{1}{3}(R+G+B) \quad (5)$$

Para se definir a região do espaço HSV do vermelho, azul e preto são necessários os valores de cada componente com base na conversão que foi feita e os resultados que cada uma das imagens fornecerá. E depois pode ser substituído numa das fórmulas acima referenciadas.

Para um melhor esclarecimento, a Figura 14 espelha o resultado destes cálculos quando são aplicados no software MATLAB utilizado neste trabalho.



Figura 14- Exemplo da conversão da imagem RGB para HSV, sendo a imagem HSV apresentada como composição RGB.

3.3. Aplicação da Segmentação e Binarização

Depois do processo de pré-processamento, é necessário definir a região de interesse, isto-é a subimagem que contém apenas o sinal de trânsito que será reconhecido, para que isto aconteça, são retidos os objetos de maior dimensão e aqueles que pelo menos possuem um número médio dos pixels do seu tamanho em cada imagem BinRED, BinBLUE e BinBlack. A imagem binária final que contém apenas o objeto de maior interesse, ou seja, neste caso a zona do sinal (BINZ), é obtida selecionando na somatória das binárias acima mencionadas, buscando o maior dos objetos das imagens processadas de BinRED, BinBLUE e BinBlack. Mas neste trabalho não destacamos e nem nos focamos muito nesta zona do sinal porque serviu apenas para ilustrar o formato do sinal em referência. A escolha anterior é justificada nas cores predominantes dos sinais que estão incluídas numa dessas três situações, a região de interesse da sua binária será delimitada por uma orla branca e se for azul, toda parte azul será destacada também pela cor branca.

Sendo assim, os pixels que pertencem ao sinal tomam o valor de 1, enquanto que os restantes tomam o valor 0.

Para um esclarecimento ilustrativo, apresentamos na Figura 15 alguns exemplos de sinais, com a imagem original, a delimitação da zona do sinal e se tiver outros elementos adicionais das cores como azul ou preta são apresentados nos painéis separados. A implementação foi feita de modo que cada pixel só possa pertencer a uma componente, sendo a prioridade definida pela ordem seguinte: original, binária vermelha, binária azul, binária preta e zona do sinal.




Figura 15- Imagem RGB a), Imagem binária vermelha b), Imagem binária azul c), Imagem binária preta d) e Zona do sinal e).

3.4. Extração das Caraterísticas de Sinais

Os sinais de trânsito descrevem algumas características que são obtidas a partir das três componentes binárias vermelha (BinRED), azul (BinBLUE) e preta (BinBlack) da imagem resultante da fase de pré-processamento.

Matematicamente as imagens binárias são obtidas considerando as seguintes condições: seja $\mathbf{B}(x, y)$ uma imagem binária X_0 por Y_0 pixels, isto-é com X_0 linhas e Y_0 colunas. E aplicando os operadores \mathbf{F} e \mathbf{G} a uma determinada imagem binária, retornam

dois histogramas que são guardadas em dois vetores f (para as linhas) e g (para as colunas), esta teoria é apresentada nas seguintes equações:

$$F(B(x, y)) = f(x) = \sum_{i=1}^{X_0} B(x, i), \quad x = 1, \dots, X_0 \quad (6)$$

$$G(B(x, y)) = g(y) = \sum_{i=1}^{Y_0} B(i, y), \quad y = 1, \dots, Y_0 \quad (7)$$

Quando se aplica os operadores **F** e **G** obtém-se dois vetores f com X_0 elementos e g com Y_0 elementos. Uma vez que as subimagens binárias contendo apenas o sinal têm tamanhos variáveis, os histogramas obtidos a partir das equações acima, não têm necessariamente o mesmo tamanho, sendo por isso necessário uniformizar as suas dimensões, de modo que seja possível definir um critério de comparação.

3.4.1. Projeções de Imagens Binárias na direção Horizontal e Vertical

Durante o desenvolvimento deste trabalho, foram criadas funções do MATLAB para extrair as projeções normalizadas de imagens binárias. A Figura 16 mostra exemplos de aplicação destas funções e as imagens binárias.

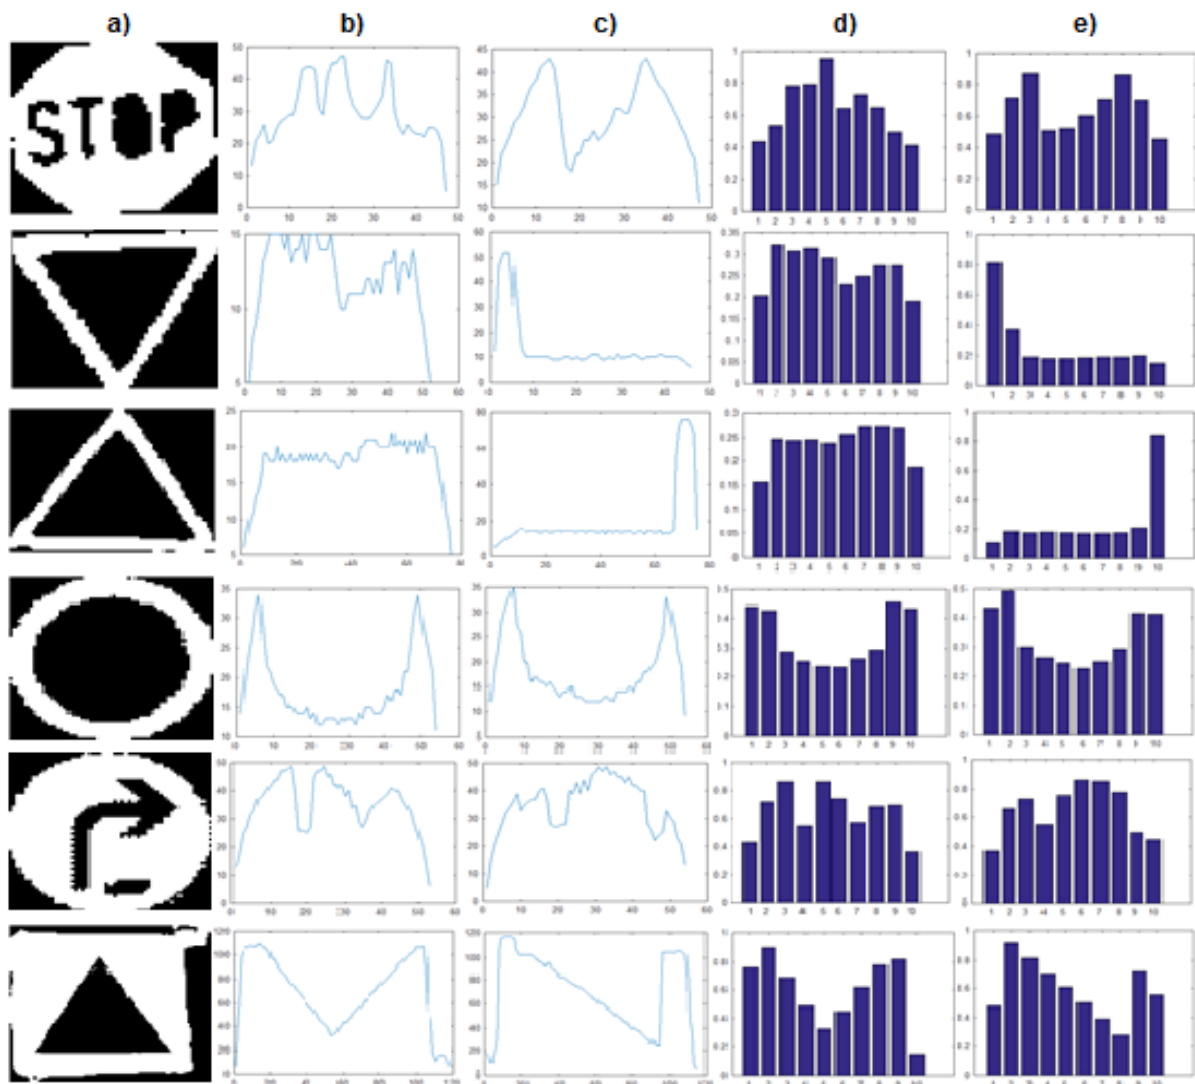


Figura 16- Imagem binária a), Histogramas de linhas b) e colunas c) e versões normalizadas (para $n=10$), para linhas d) e colunas e).

3.4.2. Normalização dos vetores

O processo de uniformização que referimos no ponto anterior neste caso é chamado de normalização de vetores e que é efetuada em duas maneiras diferentes: normalização dos seus valores e a normalização do seu número de elementos.

Buscando o exemplo anterior, a normalização dos vetores f e g é feita dividindo os respectivos vetores pelo número total de pixels da imagem, para se obter uma gama de valores no intervalo entre 0 e 1. A normalização de números de elementos de f e g é feita para os valores de n (número de elementos ou barras) previamente estabelecido. As versões modificadas dos vetores f e g são criadas inicialmente, onde cada um dos elementos dos vetores é repetido n vezes, designando-se por f' e g' possuindo os

elementos nX_0 e nY_0 respetivamente, os vetores assim obtidos a partir de f e g . Os novos vetores normalizados f^n e g^n , são calculados da seguinte forma:

$$f^n(j) = \frac{\sum_{i=1}^{X_0} f'(i + (j-1)X_0)}{X_0}, \quad j = 1, \dots, n \quad (8)$$

$$g^n(j) = \frac{\sum_{i=1}^{Y_0} g'(i + (j-1)Y_0)}{Y_0}, \quad j = 1, \dots, n \quad (9)$$

Esses vetores normalizados f^n e g^n são calculados em cada uma das suas componentes binárias BinRED, BinBLUE e BinBlack. As características extraídas correspondem os seis vetores de RGB ($f^n_{red}, g^n_{red}, f^n_{blue}, g^n_{blue}, f^n_{black}, g^n_{black}$), cada um com n elementos. O processo é ilustrado nas Figuras 17 a 20. A Figura 17 mostra um sinal na sua forma original (RGB) e as respetivas componentes binárias (Vermelho, Azul, Preto).

A Figura 18 mostra as projeções horizontais e verticais para a imagem binária vermelha, na versão original e normalizada com ($n=10$).

As Figuras 19 e 20 mostram as projeções para as componentes azul e preta.



Figura 17- Imagem original a), Imagem binária vermelha b), Imagem binária azul c), Imagem binária preta d).




Figura 18 - Histograma de linhas a) e colunas b) para imagem binária VERMELHA e versões normalizadas para linhas c) e colunas d).




Figura 19 - Histograma de linhas a) e colunas b) para imagem binária AZUL e versões normalizadas para linhas c) e colunas d).

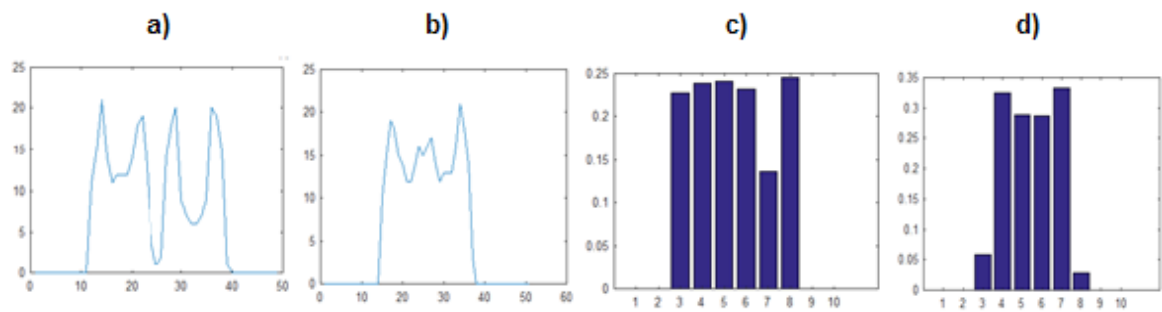


Figura 20 - Histograma de linhas a) e colunas b) para imagem binária PRETA e versões normalizadas para linhas c) e colunas d).

3.5. Reconhecimento

Geralmente em processamento de imagens, a fase de reconhecimento acontece após a fase de detecção e consequente repartição dos sinais por classes. Reconhecer significa conhecer algo novamente, o que implica com base de conhecimento e armazenamento prévio de características intrínsecas do objeto a ser reconhecido. Quando estamos a tratar de processamento de imagens, uma das principais funções da área da visão computacional é o reconhecimento de objetos. Este reconhecimento está diretamente relacionado com o reconhecimento individual dos padrões que tem como objetivo facilitar o reconhecimento do objeto como um todo.

O correto reconhecimento de sinais de trânsito é baseado na análise de padrões associados ao sinal. Embora o formato de cada classe os diferencie bastante, é muito importante conhecer o interior do sinal que permite a sua distinção entre os demais da mesma classe no geral. Então é necessária uma correta avaliação do seu interior para comparar com as informações previamente adquiridas.

3.5.1. Dificuldades durante o reconhecimento

No reconhecimento de sinais de trânsito, podem ocorrer problemas quando os sinais cujo padrão é o mesmo, como é o caso dos sinais apresentados na figura seguinte:



Figura 21- Sinais de trânsito com perfis padrões iguais.

Outros casos que podem ser encontrados no reconhecimento de imagens, são os problemas ligados nas características refletivas da sinalização, facilmente se consegue depreender que as condições e tipo de iluminação são preponderantes na tonalidade da sua qualidade de cor. Assim a cor que um determinado sinal apresente sofre uma grande variação por estar localizado numa zona de sombra ou sob iluminação direta, isso faz com que ao fotografar essas imagens sejam propensas alterações no seu perfil padrão da tonalidade de cor, o que complicará de certo modo quando essas imagens forem reconhecidas por um algoritmo computacional.

3.5.2. Treino

Um conjunto de dados de treino é um subconjunto da imagem para o qual o analista acredita que contém uma classe de alcance ou espectral, associada a uma certa classe informativa sobre todas as bandas espectrais dentro da área espacial indicada pelo analista, e no geral existem mais de uma classe espectral, ou seja, existem vários exemplares para cada classe informativa no conjunto da base de dados.

Na fase de treino desta dissertação necessitamos como entrada (inputs) o número de barras para as projeções e determinar o número de exemplares de cada classe da base de dados. O tamanho da base de dados é igualado pelo número de classe e dos caracteres, para obtermos a matriz com todos os resultados e respetiva matriz com vetores treino. Deve-se impor as condições das classes dentro da base de dados, de maneira a facilitar o seu processamento; depois determinar o número de exemplares à serem processados desta fase. Posteriormente dá-se as diretrizes da localização das imagens na base de dados em função de como foram armazenadas. Chama a função das imagens binárias, os vetores de todas as imagens binárias e os seus respetivos números de barras; e na matriz

resultante igualamos todos vetores, dos exemplares até a classe. Por último a matriz treino é calculada como média da matriz resultante por todas as linhas e colunas das classes existentes, sendo exportada para um ficheiro texto.

3.5.3. Classificação

Há um grande número de métodos de classificação de dados, com diferentes graus de complexidade e eficácia.

Em função dos conceitos de cada uma das classificações, neste trabalho usamos a classificação supervisionada paramétrica que consiste em utilizar amostras de entidades conhecidas. O algoritmo classifica cada sinal através da comparação dos vetores das projeções normalizadas. Usa-se a distância Euclidiana para comparar os vetores. De forma resumida esta classificação tem como seguintes procedimentos:

- Seleciona os dados de treino;
- Escolha dos parâmetros relevantes da imagem a serem classificada;
- Obtenção da função discriminante, que foi obtida por método não estatístico (distribuição livre);
- Eliminação dos parâmetros não relevantes;
- Testes com as imagens fora do conjunto de treino;
- Avaliar a precisão da classificação.

Capítulo 4- Avaliação Experimental

Neste capítulo são apresentados os resultados da avaliação experimental, baseada na metodologia desenvolvida e descrita no capítulo 3. As imagens usadas foram as da base de dados GTSRB (Alemã) e a base de dados da FCUP, utilizada por Gonçalves em 2009.

4.1. Conjunto de dados

Conforme referenciamos no início deste capítulo, a base de dados GTSRB (Alemã) foi a principal na execução deste trabalho e nela consta um total de 14422 imagens, subdivididas em 42 classes. Estas imagens são de tamanhos pequenos e tonalidades muito diversificadas, algumas em boas condições e outras quase impercetíveis, foram escolhidas 26 classes, tentando aproximar ao máximo as características deste conjunto de dados à base de dados da FCUP. Tentamos selecionar as mesmas classes da base de dados da FCUP, mas encontramos a inexistência de 11 classes e que foram substituídas por outras semelhantes. Em destaque vimos que nesta base de dados não há sinais de informação e de paragem ou estacionamento proibida.

Com toda esta diferença e na seleção feita de 26 classes com 9780 imagens, no nosso trabalho usamos apenas 1560 imagens, repartidas em 260, sendo que foram usadas 10 imagens por cada classe na fase de treino e 1300 para a fase de teste com 50 imagens por classe.

4.2. Estratégia de Avaliação

Na experimentação feita nessa base de dados GTSRB, foram utilizados dez (10) exemplares de cada classe na fase de treino fazendo um total de duzentas e sessenta (260) imagens das vinte e seis (26) classes e para a fase de teste usamos cinquenta (50) exemplares de cada classe e fazendo uma somatória de mil e trezentas (1300) imagens.

A Figura 22 mostra as 26 classes de cada uma das bases de dados. Há mais sinais comuns às duas (2) bases de dados (por exemplo STOP) e outros casos onde não existe o mesmo sinal nas duas bases de dados.

Imagens da GTSRB	 14	 13	 27	 26	 21	 11	 20	 19
Imagens da FCUP	 1	 2	 3	 4	 5	 6	 7	 8
Imagens da Standard								
Imagens da GTSRB	 17	 15	 16	 10	 1 - 7	 9	 29	 24
Imagens da FCUP	 9	 10	 11	 12	 13 - 17	 18	 19	 20
Imagens da Standard								
Imagens da GTSRB	 33	 35	 38	 40	 39	 28		
Imagens da FCUP	 21	 22	 23	 24	 25	 26		
Imagens da Standard								

Figura 22- Comparação de Sinais Standard com os que foram usados nas bases de Dados.

Observando a Figura 22, vimos que as imagens são diferentes entre si em ambas as bases de dados, que nem têm aproximação com o padrão standard. Apesar de existirem normas bem definidas internacionalmente, que os países cumprem e tentam aplicar, como por exemplo em Portugal a (DGV 2003), os sinais de trânsito existentes nas estradas diferem das representações standard, conforme se pode observar na Figura 22.

Para além disso, temos a destacar também dentro da base de dados e no conjunto da mesma classe a diversificação de imagens. Como prova disso apresentamos algumas imagens com essas variações na Figura 23, e que às vezes são efeitos do tempo da exposição, outros sinais por vandalização e até a própria máquina em que foi tirada a foto. A numeração desordenada que apresentam as classes das imagens GTSRB na Figura 22, deve-se à posição em elas se encontram na base de dados e para facilitar quem tiver de utilizar como referência este trabalho, não quisemos alterá-las para uma melhor compreensão e orientação. E as classes em não existiam no trabalho de Gonçalves (2009) foram acrescentadas, de modo a complementar e equilibrar o número na base de dados.

Os seguintes exemplos ilustram algumas variações relativamente ao formato do sinal, tamanho, tonalidade de cor e inclusive o seu posicionamento das imagens Alemãs.



Figura 23- Alguns exemplos das mesmas classes com diversificação.

Com base a Figura 23, observa-se que as imagens de ambas as bases de dados têm muitos defeitos no ponto de vista visual até de posicionamento. Neste caso é de realçar que as imagens da base de Dados GTSRB, apresentam mais defeitos, quer no ponto de vista da intensidade de cor, quer no seu tamanho.

4.3. Resultados na Base de Dados GTSRB

Foi criado um script MATLAB para executar testes em todo o conjunto de dados. Tendo sido previamente criado um script de treino, que cria um ficheiro texto de treino. O teste consiste em efetivar o processo de classificação de todas as imagens disponíveis para teste (1300 para a base de dados GTSRB) e organizar os resultados para o conjunto de imagens.

A experiência (treino e teste) foi repetida doze (12) vezes, para diferentes valores do parâmetro de normalização (Nº Barras dos Histogramas / Projeções).

A precisão média é calculada como o quociente entre o número de casos bem classificados e o número total de casos.

Número de Barras	Precisão encontrada
	Com 10 exemplares de treino e 50 de teste
10	0.687
12	0.688
15	0.709
20	0.711
25	0.719
30	0.719
35	0.720
40	0.719
45	0.722
50	0.722
55	0.721
60	0.722

Tabela 1 – Resultados teste na base de Dados GTSRB.

A Tabela 1 mostra os resultados das precisões obtidas no conjunto de dados GTSRB em função do parâmetro de normalização n (Nº Barras). Observando a Tabela, vemos que a variação de número de barras na normalização de histogramas / projeções condiciona a precisão da classificação, obedecendo uma tendência crescente sucessiva.

Em função dessa tabela, podemos afirmar que o número de barras encontrado com valores alto da precisão é o de 50 barras, que permite transmitir uma informação adequada no reconhecimento das imagens da base de dados GTSRB. Esta precisão possibilita espelhar ao analista de dados que existe uma variação inadequada nas imagens dentro das classes; ou seja, as imagens não reúnem qualidades próprias de cores universalmente usadas.

Neste ponto apresentamos a Tabela 3 da matriz de confusão relacionada com a classificação dos sinais da base de dados GTSRB, referentes no caso do treino, $t=10$, número de exemplares de teste $ex=50$ e número de barras do histograma $n=50$, onde o classificador faz a média das diferenças absolutas das matrizes do número das classes partindo dos dados do treino realizado. A taxa de sucesso é de 72.2% num quociente correspondente de 1300 imagens de teste e 260 imagens do treino, o que perfaz um total de 1560 imagens selecionadas aleatoriamente nesta base de dados.

A numeração da linha e coluna azul desta tabela, representa a posição das classes na base de dados GTSRB e a diagonal é o número de exemplares que foram bem classificados em cada classe, o que corresponde um total de 939, e fazendo a diferença de 361 imagens que foram mal classificadas no universo de 1300 de teste. E os números marcados a cor vermelha, foram considerados como mais problemáticas.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26
ID.	14	13	27	26	21	11	20	19	17	15	16	10	1	2	3	5	7	9	29	24	33	35	38	40	39	28
1	14	24	16	0	9	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	13	21	25	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	27	28	1	11	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
4	26	16	0	0	33	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	21	15	0	0	0	33	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	11	0	0	0	0	0	39	1	0	0	0	3	6	0	0	0	0	0	0	1	0	0	0	0	0	0
7	20	2	0	0	0	0	4	42	0	0	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0
8	19	0	0	0	0	0	0	50	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	17	0	0	0	0	0	0	0	49	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
10	15	0	0	0	0	0	0	0	0	42	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0
11	16	3	0	0	2	12	0	0	0	0	0	14	19	0	0	0	0	0	0	0	0	0	0	0	0	0
12	10	0	0	0	0	0	0	0	0	0	0	50	0	0	0	0	0	0	0	0	0	0	0	0	0	0
13	1	0	0	0	0	0	0	0	0	0	0	0	50	0	0	0	0	0	0	0	0	0	0	0	0	0
14	2	0	0	0	0	0	0	0	0	0	0	0	0	47	0	1	0	1	0	1	0	0	0	0	0	0
15	3	0	0	0	0	0	0	0	0	0	0	0	0	0	47	0	0	0	0	0	3	0	0	0	0	0
16	5	0	0	0	0	0	1	3	0	0	0	0	0	7	1	31	5	0	0	0	2	0	0	0	0	0
17	7	0	0	0	0	0	0	0	1	0	0	0	0	0	0	6	39	0	4	0	0	0	0	0	0	0
18	9	1	0	0	0	0	0	0	0	0	0	0	0	0	3	0	2	14	17	0	13	0	0	0	0	0
19	29	0	0	0	0	0	0	1	0	0	0	0	0	11	0	0	0	0	38	0	0	0	0	0	0	0
20	24	0	0	0	0	0	0	3	0	0	0	0	0	19	3	0	0	1	0	18	6	0	0	0	0	0
21	33	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	2	47	0	0	0	0	0
22	35	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	42	0	4	0	4	0
23	38	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	49	0	0	1	0
24	40	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	29	17	4	0
25	39	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	18	32	0	0
26	28	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	44	0

Tabela 2 – Matriz de confusão das imagens da base de dados da GTSRB com $n = 50$.

4.4. Resultados na Base de Dados da FCUP

Já que em 2009 se fez um trabalho semelhante de reconhecimento automático de sinais de trânsito com a base de dados da FCUP, vimos a necessidade de tentar adaptar o nosso algoritmo nas funções da leitura das imagens RGB para compararmos o comportamento da precisão na classificação. Conforme a Tabela 2 nos apresenta, observa-se que nenhuma das precisões que encontramos correspondem com a precisão do trabalho de Gonçalves (2009), onde nos apresenta 94.9% com a distância euclidiana.

Querendo descobrir a falha desse reconhecimento do nosso algoritmo, vimos que o problema reside na segmentação que foi feita naquele trabalho. Resumidamente

podemos afirmar que para o reconhecimento de imagens, deve-se investir maior tempo e empenho na segmentação e binarização, para que não haja falhas nos componentes de cada classe de imagens da base de dados.

A tabela seguinte nos apresenta um conjunto de resultados obtidos numa fase de treino com três (3) exemplares e sete (7) exemplares na fase de teste. Onde resultou uma classificação acima da média e com um máximo de 55% da precisão, fazendo uma diferença de 39.9% em relação os 94.9% encontrado em 2009.

Número de Barras	Precisão encontrada
	Com 3 exemplares de treino e 7 de teste
10	0.511
12	0.522
15	0.533
20	0.539
25	0.550
30	0.539
35	0.544
40	0.550
45	0.550
50	0.533
55	0.533
60	0.533

Tabela 3 – Resultados teste na base de Dados da FCUP.

A partir dos resultados da tabela 2 onde usamos o perfil das imagens da base de dados da FCUP, mas com número de caso do treino, $t = 3$, número de exemplares de teste $ex. = 7$ e número de barras do histograma $n = 25$, onde o classificador faz a média das diferenças absolutas das matrizes do número das classes e com os dados do treino realizado. A taxa de sucesso é de 55.0% num quociente correspondente de 182 imagens de teste e 78 imagens do treino, o que perfaz um total de 260 imagens.

Na diagonal da matriz de confusão da base de dados da FCUP (Tabela 4), aparece o número de exemplares que foram bem classificados em cada classe, o que corresponde um total de 100, e fazendo a diferença de 82 imagens que foram mal classificadas no universo de 182 de teste. E os números marcados a cor vermelha, foram considerados como representantes das classes mais problemáticas.

ID.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26
1	6	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	1	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	2	1	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0
5	0	1	0	1	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	1	0	1	0	4	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	1	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	2	0	1	1	1	0	2	0	0	0	0	0	0	0
14	0	0	0	0	0	0	1	0	0	0	0	2	2	1	0	1	0	0	0	0	0	0	0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	5	0	0	0	0	0	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	5	0	0	0	0	0	0	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	5	0	1	0	0	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	1	0	0	0	0	0	0	0
19	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	6	0	0	0	0	0	0	0
20	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	2	3	0
22	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	3	0	2	1	0
23	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	1	4	0
24	1	0	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	1	2	0	0
25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	1	0	4	0
26	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	4	0

Tabela 4 – Matriz de confusão das imagens da base de dados da FCUP

4.5. Discussão dos Resultados

O problema constatado no reconhecimento de sinais de trânsito neste trabalho, relaciona-se com a discordância de padrões entre sinais com a mesma informação ou classe, visto que os sinais sofreram alterações nas normas convencionais internacionalmente estabelecidas, por outro a própria qualidade da máquina que se utilizou para fotografar as imagens. Essas dificuldades serão contínuas até as fases posteriores do processamento dessas imagens; tais como segmentação e binarização, como é o caso

encontrado no desenvolvimento desse trabalho. As triagens das Figuras abaixo mostram essas dificuldades que podem aparecerem e as que encontramos durante a execução deste trabalho.

A Figura 24 apresenta algumas imagens das duas bases de dados (GTSRB e FCUP), comparando-as com imagens que têm o perfil padrão universalmente usado. Estes exemplos apresentados são alguns dos casos que o algoritmo aplicado neste trabalho não reconheceu adequadamente.




Figura 24- Imagem da GTSRB a), Imagem Standard b), Imagem da FCUP c).

Estas mudanças da intensidade na iluminação levam, não só, a que as cores fiquem mais escuras ou mais claras, mas também podem alterar o tom da cor da imagem. Esta mudança dificulta o processo de reconhecimento, uma vez que é necessário definir uma gama de variação na busca da determinação da cor. Assim, se a gama da variação considerada for demasiado abrangente, é considerado ruído, o que aumenta a ocorrência de resultados falsos e pode inclusivamente inviabilizar o reconhecimento desejado. E por outro lado, se a gama da variação considerado for demasiado restrita, não será reconhecido o sinal que se encontra sob condição de iluminação menos favorável.

Alguns exemplos de segmentação das imagens a cor, bem como as respetivas imagens binárias são representados nas Figuras 25 a 29. Quando os sinais sofreram alterações na tonalidade de cor universal, e que apresentaram muitas anomalias no seu reconhecimento. O exemplo da Figura 25 demonstra o reconhecimento das imagens GTSRB anteriormente comparadas pelas standards.




Figura 25- Imagens da GTSRB: original a), binária vermelha b) e binária preta c).

Os casos constatados de mau reconhecimento de algumas imagens da base de dados GTSRB, sucederam também na base de dados da FCUP, com alguns casos piores no seu reconhecimento, conforme espelha o exemplo da Figura 26.




Figura 26- Imagens da FCUP: original a), binária vermelha b) e binária preta c).

Outro elemento em destaque que dificultou o reconhecimento das imagens, é a presença de ruído envolvente ao sinal. Existem diversas situações em que o reconhecimento é dificultado devido à presença de elementos estranhos, cuja cor e forma se assemelham com os sinais de trânsito. Esses elementos são maioritariamente, painéis de publicidades, paredes das casas, telhados, vegetação, entre outros. Assim na Figura 27, estão explícitas situações onde aparecem alguns desses elementos que dificultaram o processo de reconhecimento e que levaram a obtenção de resultados falsos.

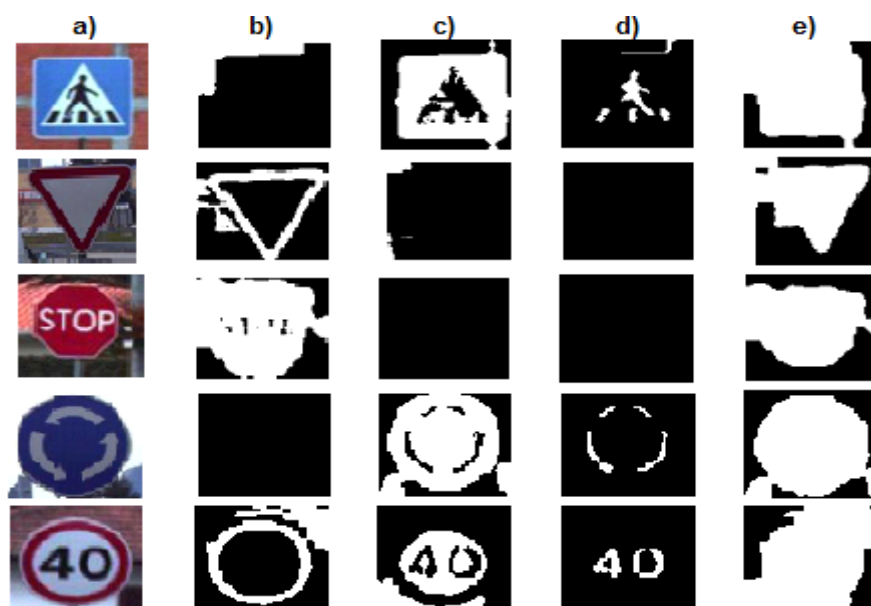


Figura 27- Imagens original a), binária vermelha b), binária azul c), binária preta d) e zona do sinal e).

Para comprovar a eficácia do algoritmo deste trabalho, são apresentados alguns exemplos das mesmas classes que forma bem reconhecido e consequentemente a sua classificação. A Figura 28 mostra 3 imagens da base de dados da GTSRB com reconhecimento bem-sucedido.




Figura 28- Imagens da GTSRB: original a), binária vermelha b) e binária preta c).

A Figura 29 mostra 3 imagens da base de dados da FCUP com um reconhecimento bem sucedido.




Figura 29- Imagens da FCUP: original a), binária vermelha b) e binária preta c).

O método de reconhecimento aplicado neste trabalho consiste em ler a imagem original (RGB) e converter para HSV, feito isso, busca-se os valores dos pixels da classe da imagem onde aplicamos o fecho e eliminação dos lugares vazios de modo a permitir a obtenção da região de interesse da imagem a ser reconhecido com todas suas componentes. Posteriormente faz-se uma somatória das imagens binárias vermelhas e azul para determinar a zona que limita o sinal, onde também são aplicados o fecho e eliminação de outros possíveis ruídos, filtrando com o máximo da área que limita a zona total de interesse do sinal.

Em seguida faz-se um corte nas imagens binárias de interesse, vermelha, azul e preta, para extrair as zonas à volta do sinal que não nos interesse, para quando buscarmos os gráficos e histogramas tenhamos apenas a informação relevante do nosso interesse ou do sinal em causa. Para fazer este corte soma-se as linhas e colunas da imagem binária da zona do sinal, depois busca-se uma tolerância nos primeiros e últimos elementos das linhas e colunas deste sinal. A partir dessa tolerância encontrar a máxima e mínima das linhas e colunas que é superior ou igual à tolerância e por último aplicar o corte na imagem de saída.

% Corte da imagem Binária de saída usando a informação da zona do sinal.

- S_linhas = sum(BINZ,2); % somar as linhas da binária zona.
- S_col = sum(BINZ,1); % somar as colunas.
- Tol = 5; % tolerância nos primeiros e últimos das linhas e colunas.
- l_min = min(find(S_linhas >= tol)); % Encontrar o mínimo das linhas.
- l_max = max(find(S_linhas >= tol)); % Encontrar o máximo das linhas.
- c_min = min(find(S_col >= tol)); % Encontrar o mínimo das colunas.
- c_max = max(find(S_col >= tol)); % Encontrar o máximo das colunas.
- Imagem_saída = Imagem_saída(l_min:l_max,c_min:c_max); % Aplicar o corte na imagem de saída.

Durante a execução deste trabalho, optamos nas funções discriminantes que requer uma divisão do espaço de características da imagem (em três sub-imagens), caso a imagem original oferece esses parâmetros. No caso em estudo dos sinais de trânsito, sempre estaremos na ausência de uma das sub-imagens, porque os sinais de trânsito fornecidos nas bases de dados são compostos por: vermelha e azul, vermelha e preta, azul e preta, apenas azul ou apenas vermelha. Esta teoria é sustentada na Figura 30.




Figura 30-Imagem apenas com azul a), Imagem apenas com vermelha b), Imagem com vermelha e preta c), Imagem com azul e preta d), Imagem com vermelha azul e).

O classificador recebe como inputs uma imagem RGB e o número de barras das projeções da imagem. Chama o ficheiro de treino e os dados inscrito no treino, ainda chama a função que lê a imagem RGB, os vetores de todos componentes das binárias, para formar um único vetor, para compor a matriz com o número de linhas igual das classes existentes.

A classificação aplicada neste trabalho é a média das diferenças absolutas das matrizes de número total das classes (26 neste caso), com os dados do ficheiro de treino efetuado. Implementa-se os fatores da normalização dos vetores das componentes, que é uma soma das somas desses vetores.

Capítulo 5- Conclusões

Numa primeira abordagem da tarefa de reconhecimento automático de sinais de trânsito em imagens digitais, é usual a ideia de ser uma tarefa de fácil execução. Contudo, esta tarefa revela uma maior complexidade do que se julgaria à partida, uma vez as dificuldades encontradas são em grande número e algumas de difícil resolução. Uma das complexidades encontradas nesta tarefa, é o fato de não existir na comunidade científica um método de reconhecimento que reúne consenso. Só trabalhando neste tema é que se tem a percepção da quantidade de dificuldade que surge. Como não bastasse, todos os métodos e técnicas utilizados para colmatar essas dificuldades, têm de ser suficientemente eficazes ao ponto de conseguir reconhecer o sinal num instante. Embora com as dificuldades inerentes à tarefa, foi possível desenvolver um método que reconhece automaticamente os sinais de trânsito com um nível de precisão razoável.

O presente trabalho tinha como objetivo desenvolver um método de reconhecimento automático de sinalização vertical de trânsito, usando as imagens da base de dados GTSRB, nomeadamente da sinalização de perigo e alguma da sinalização de regulamentação (cedência de passagem, proibição e obrigação) que possuem as cores vermelha, azul e preta. O algoritmo foi desenvolvido e implementado e consiste em extrair as características das imagens, a partir dos histogramas das componentes vermelha, azul e preta da imagem original, após esta ter sido convertida em HSV. Com este algoritmo, a classificação feita neste trabalho foi estudar o impacto da variação de número de barras nos histogramas normalizados.

Estabelecer como meta para conclusão desta tese de reconhecimento de sinais de trânsito na totalidade mostrou ser uma tarefa bastante complexa e um pouco ambiciosa. Até à data, apesar de diversas pesquisas proporem inúmeras soluções para melhorar a eficiência de sistemas desta natureza, reconhecer sinais de trânsito ainda demonstra ser uma tarefa verdadeiramente desafiadora.

Embora não se tenha alcançado um sucesso total no reconhecimento, considera-se o valor obtido como satisfatório tendo em conta a simplicidade do algoritmo implementado neste trabalho. O reconhecimento dos sinais da base de dados GTSRB, referentes no treino, $t = 10$, número de exemplares de teste $ex. = 50$ e número de barras do histograma $n = 50$, onde o classificador apresentou uma taxa de sucesso de 72.2% para 26 classes, o que se pode considerar um resultado satisfatório. Relativamente aos resultados é de realçar que as classes que tiveram um reconhecimento total ou quase,

foram: 19, 12, 13, 23, 9, 21, 15, 14, 7 e 22, estando num intervalo de [42, 50] imagens de teste bem reconhecidas na base de dados GTSRB.

Comparar o desempenho da classificação e reconhecimento dos dois conjuntos de dados, os resultados obtidos neste algoritmo não são iguais com as que apresenta Gonçalves (2009). O teste feito utilizando as imagens da base de dados da FCUP, com número de caso do treino, $t = 3$, número de exemplares de teste $ex = 7$ e número de barras do histograma $n = 25$, o classificador apresenta uma média da precisão de 55%, o que nos remete a uma responsabilidade nos trabalhos futuros.

Podemos ainda dizer que nessa base de dados da FCUP os resultados das classes com um bom reconhecimento foram: 2, 7, 8, 9, 1, 3, 12, 18, 19, 5, 16, 17, 6 e 25, essas classes tiveram num intervalo de reconhecimento de [4,7] imagens de teste bem reconhecidas na base de dados da FCUP.

Com base o desenvolvimento deste algoritmo, como trabalho futuro sugere-se um investimento de tempo e paciência de grande profundidade na fase de segmentação e binarização, de modo a obter todos os detalhes necessários das imagens quanto a sua variação dos parâmetros de cor, nomeadamente no espaço RGB (vermelho, azul, preto), assim como no espaço HSV (tonalidade de cores, saturação, valor), permitindo desta maneira excluir todos elementos extras presentes na envoltória da imagem. Com isso deverá ser possível de elaborar um algoritmo mais robusto de reconhecer os detalhes dos sinais de trânsito nessas bases de dados. O método utilizado provou fornecer dados interessantes, mas não suficientemente fiáveis, e por isso, deverá ser redesenhado. Outra melhoria possível é a utilização de classificadores mais sofisticados tais como máquinas de suporte vetorial (SVM) ou redes neuronais.

Referências

- Alves, F. O. (2004). *Reconhecimento Inteligente de Sinais de Trânsito Brasileiros*. in Centro de Ciências exactas e Tecnológicas. São Leopoldo. Universidade do Vale do Rio dos Sinos. São Leopoldo. p.74.
- Andrey, Vavilin, Jo, Kang, & Hyun. (2006). *Automatic Detection and Recognition of Traffic Sign Using Geometric Structure Analysis Sistem*.
- Ayoub, E., Mahamed, E. A., & Ilyas, E. J. (2016). Traffic Sign Detection and Recognition Basead on Random Forests.
- Azami, S., Katahara, S., & Aoki, M. (1996). *Ronte Guindance Sign Identification Using 2-D Structural Description. Proceeding of the IEEE Vehicle Symposium*, p.78-81.
- Correia, D. V. (2010). *Sistema para Detecção, Reconhecimento e Classificação de Sinalética em Tempo Real*. Covilhã.
- Da Silva, F. A., Artero, A. O., De Paiva, M. S., & Barbosa, R. L. (2013). *Uma Metodologia para Detector e Roconhecer Placas de Sinalização de Trânsito*.
- Da Silva, F. A., Olivette, A. A., Paiva, M. S., & Barbosa, R. L. (2013). *Uma Metodologia para Detectar e Reconhecer Placas de Sinalização de Trânsito*. Brasil.
- De la Escalera, A., Armingol, J. M., & Mata, M. (2002). *Traffic Sign Recognition and Analysis for Intelligent Vehicules. Division of Systems Engineering and Automation, Universidad Carlos III de Madrid, C/Butarque 15, 28911 Legane´s, Madrid, Spain. Image and Vision Computing*, p. 247–258.
- De la Escalera, A., Moreno, L., Salichs, M., & Armingol, J. (1997). *Road Traffic Sign Detection and Classification*. (44ª ed.). *IEEE Transactions on Industrial Electronics*, p.848-859.
- De Sousa, A.M.R., *Localização Automática de Objectos em Sequências de Imagens*. 2005, Universidade do Minho: Braga. p. 15-81.
- DGV (2003), *Guia de Sinalização Rodoviária*. Ministério da Administração Interna, Lisboa. Obtido em 05 de Fevereiro de 2017, <https://docs.com/filipa-louseiro/9157/livro-sinalizacao-rodoviaria>.
- Dos Santos, F. M. (2013). *Reconhecimento Automático de Sinalização Vertical de Trânsito a partir de Dados Vídeos de um Sistema de Mapeamento Móvel*.Universidade de Lisboa. Faculadade de Ciências, Departamento de Engenharia, Geofísica e Energia. Dissertação de Mestrado em Engenharia Geográfica, p. 4-52.
- Fang, Z. Y., Yuda, S., Anderson, V., & Short, L. (2003). *Echocardiographic Detection of Carly Diabetic myocardial Disease. Computer Vision and Image Understanding*, (95ª ed.), p. 237-268.
- Fatin, Z., & Bogdam, S. (2012). *Real-Time Traffic Sign Recognition in There Stages*. Robotics Center, Mines ParisTech, 60 Bd Saint-Michel, 75006 Paris, France. journal homepage: www.elsevier.com/locate/robot. p.17-23.

- Fleyeh, H., & Dougherty, M. (2008). "Traffic Sign Classification Using Invariant Features and Support Vector Machines". *2008 IEEE Intelligent Vehicle Symposium*, p. 530-535.
- Foley, J. (1995). *The Standard Computer Graphics Textbook*.
- Foley, J. e. (1997). *Computer Graphics: Principles and practice*. (2ª ed.). Rewood City: Addison-Wesley ISBN-0-201-84840-6, p. 354-362.
- Gil-Jiménez, P., Maldonado-Báscon, S., Gómez-Moreno, H., López-Arroyo, S., & López-Ferreras, F. (2008). *Traffic sign shape classification and çocalization basead on the normalized FFT of the blobs and 2D homographies*. *Signal Processing*, Vol. 88, p. 2943-2955.
- Gonçalves, I. J. (2009). *Reconhecimento Automático de Sinais de Trânsito em Imagens de Vídeo Digitais*. Porto. p. 17-54.
- Gonzalez, R. C., & Woods, R. E. (1993). *Digital Image Processing*. Addison-Wesley Publishing Company Inc.
- Gonzalez, R. C., & Woods, R. E. (2002). *Deteção e Reconhecimento de Imagens*. São Paulo.
- Gonzalez, R. C., Woods, R. E., & Eddins, S. L. (2004). *Digital Image Processing Using Matlab - Fundamentos Modelo de Imagens*. 3ª ed. p. 213-220.
- Hatzidimos, J. (2004). *Automatic Traffic Sign Recognition in Digital Imagens, in Conference on Theory and Applications of Mathematics and Informatics*. Grecia. p. 174-184.
- Hsu, S., & Huang, C. (2001). *Road SignDetection and Recognition Using Matching Pursuit Method*. *Image and Vision Computing*, Image and Vision Computing, www.elsevier.com/locate/imavis. *Electrical Engineering Department, National Tsing-Hua University, Hsin-Chu 30043, Taiwan, ROC*. p.119–129.
- Invicta, E. d. (2002). <http://www.invicta.pt/codigo/sinalizacao.asp>. Obtido em 19 de Outubro de 2016, de <http://www.invicta.pt/codigo/sinalizacao.asp>.
- NXP, "NXP LPC2104_2105_2106_7", NXP 2008.
- Phalguni, Ganapatli, Kishan, Madumbu, Venugopala, & al., e. (2013). Design and Implementation of an Automatic Traffic Sistem.
- Picciolo, G., De Micheli, E., Parodi, P., & Campani, M. (1996). *Robust method for road sign detction and recognition*. *Image and Vision*, Vol. 14, p. 209-223.
- Sampaio, J. E. (2010). *Deteção e Reconhecimento de Sinais de Trânsito em Tempo Real*. UMinho, Dissertação do Mestrado. p. 6-18.
- Selcan, K. b., Huseyin, G., Ozgun, O., Cuneyt, A., Serkan, G., & al., e. (2016). "On Circular Traffic Signs Detection and Recognition" *Department of Computer Engineering, Anadolu University, Eskisehir,Turkiye*. Expert Systems With Applications. journal homepage: www.elsevier.com/locate/eswa. p. 67–75
- Shneier, M. (2005). *Road Sign Detection an Recognition, in IEEE Computer Society International Conference on Computer Vision and Pattern Recognition*.

- Souki, M. A., B., L., & Abid, M. (2008). *An Embedded System for Real-time Traffic Sign Recognizing*, in *3rd International Conference Design and Test Workshop*. p.273-276.
- Sousa, A. M.R. (2005). *Localização Automática de Objectos em Sequências de Imagens*. Braga: Universidade do Minho. Braga, p. 15-81.
- Yehua, S., Ka, Z., Chun, Y., Cheng, L., & Jian, L. (2008). *Automatic Detection and Recognition of Traffic Sign in Stereo Images Basead on Features and Probabilistic Neural Networks*. *Proc. SPIE 7000, Optical and Digital Image Processing, From Conference Volume 7000*. p. 452-468.
- Yishan, G., Wei, Z., Zhijia, Z., & Yuanyuan, L. a. (2015). *Research and Implementation of Traffic Sign Recognition System*. *Wireless Communications, Networking and Applications Volume 348 of the series Lecture Notes in Electrical Engineering*, p. 553-560.

Anexo A – Assinaturas das componentes de cada classe de GTSRB

Classe 01.



Figura A 1- Imagem original da classe 01 com todas suas componentes.




Figura A 2- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 3- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 02.



Figura A 4- Imagem original da classe 02 com todas suas componentes.




Figura A 5- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 6- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 03.



Figura A 7- Imagem original da classe 03 com todas suas componentes.




Figura A 8- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 9- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 05.



Figura A 10- Imagem original da classe 05 com todas suas componentes.




Figura A 11- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 12- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 07.



Figura A 13- Imagem original da classe 07 com todas suas componentes.




Figura A 14- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 15- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 09.



Figura A 16- Imagem original da classe 09 com todas suas componentes.




Figura A 17- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 18- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 10.



Figura A 19- Imagem original da classe 10 com todas suas componentes.




Figura A 20- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 21- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 11.



Figura A 22- Imagem original da classe 11 com todas suas componentes.




Figura A 23- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 24- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 13.



Figura A 25- Imagem original da classe 13 com todas suas componentes.




Figura A 26- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 14.



Figura A 27- Imagem original da classe 14 com todas suas componentes.




Figura A 28- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 15.



Figura A 29- Imagem original da classe 15 com todas suas componentes.




Figura A 30- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 16.



Figura A 31- Imagem original da classe 16 com todas suas componentes.




Figura A 32- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 33- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 17.



Figura A 34- Imagem original da classe 17 com todas suas componentes.




Figura A 35- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 19.



Figura A 36- Imagem original da classe 19 com todas suas componentes.




Figura A 37- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 38- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 20.



Figura A 39- Imagem original da classe 20 com todas suas componentes.




Figura A 40- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura A 41- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 35.



Figura A 42- Imagem original da classe 35 com todas suas componentes.




Figura A 43- Histogramas originais de azul em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Anexo B – Assinaturas das componentes de cada classe de FCUP

Classe 1.



Figura B 1- Imagem original da classe 1 com todas suas componentes.




Figura B 2- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 2.



Figura B 3- Imagem original da classe 2 com todas suas componentes.




Figura B 4- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 3.



Figura B 5- Imagem original da classe 3 com todas suas componentes.




Figura B 6- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 7- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 4.



Figura B 8- Imagem original da classe 4 com todas suas componentes.




Figura B 9- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 10- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 5.



Figura B 11- Imagem original da classe 5 com todas suas componentes.




Figura B 12- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 13- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 6.




Figura B 14- Imagem original da classe 6 com todas suas componentes.




Figura B 15- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 16- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 7.



Figura B 17- Imagem original da classe 7 com todas suas componentes.




Figura B 18- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 19- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 8.



Figura B 20- Imagem original da classe 8 com todas suas componentes.




Figura B 21- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 22- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 9.




Figura B 23- Imagem original da classe 9 com todas suas componentes.




Figura B 24- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 10.



Figura B 25- Imagem original da classe 10 com todas suas componentes.




Figura B 26- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 27- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 11.



Figura B 28- Imagem original da classe 11 com todas suas componentes.




Figura B 29- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 30- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 12.



Figura B 31- Imagem original da classe 12 com todas suas componentes.




Figura B 32- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 33- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 13.



Figura B 34- Imagem original da classe 13 com todas suas componentes.




Figura B 35- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 36- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 14.



Figura B 37- Imagem original da classe 14 com todas suas componentes.




Figura B 38- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 39- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 15.



Figura B 40- Imagem original da classe 15 com todas suas componentes.




Figura B 41- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 42- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 16.



Figura B 43- Imagem original da classe 16 com todas suas componentes.




Figura B 44- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 45- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 17.



Figura B 46- Imagem original da classe 17 com todas suas componentes.




Figura B 47- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 48- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 18.



Figura B 49- Imagem original da classe 18 com todas suas componentes.




Figura B 50- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 51- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 19.



Figura B 52- Imagem original da classe 19 com todas suas componentes.




Figura B 53- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 54- Histogramas originais de azul em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 20.



Figura B 55- Imagem original da classe 20 com todas suas componentes.




Figura B 56- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).




Figura B 57- Histogramas originais d azul em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 21.



Figura B 58- Imagem original da classe 21 com todas suas componentes.




Figura B 59- Histogramas originais de azul em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 22.



Figura B 60- Imagem original da classe 22 com todas suas componentes.




Figura B 61- Histogramas originais de azul em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 23.




Figura B 62- Imagem original da classe 23 com todas suas componentes.




Figura B 63- Histogramas originais de azul em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 24.



Figura B 64- Imagem original da classe 24 com todas suas componentes.




Figura B 65- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 25.



Figura B 66- Imagem original da classe 25 com todas suas componentes.




Figura B 67- Histogramas originais da vermelha em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Classe 26.



Figura B 68- Imagem original da classe 26 com todas suas componentes.




Figura B 69- Histogramas originais de azul em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).






Figura B 70- Histogramas originais da preta em linhas a) e colunas b) e histogramas normalizados em linhas c) e colunas d).

Anexo C – Imagens representativas da base de dados GTSRB.

Classe 09



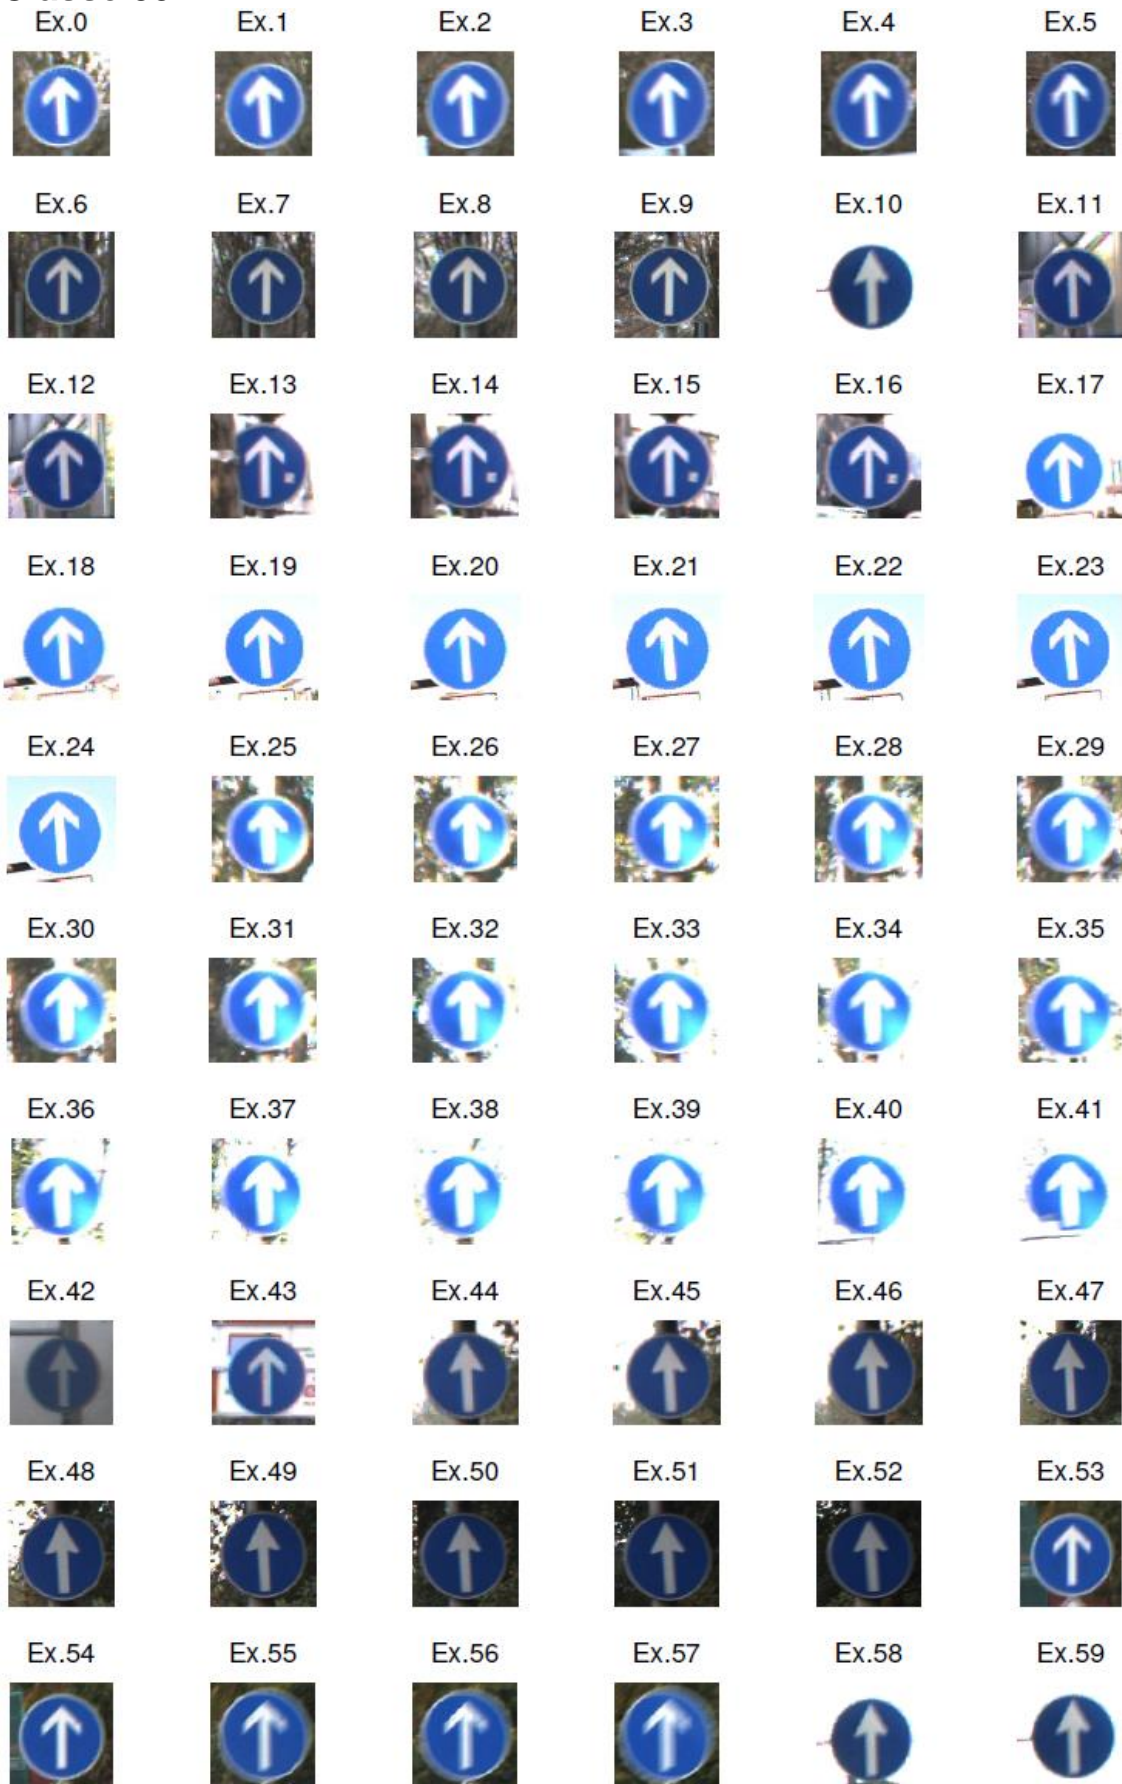
Classe 11



Classe 14



Classe 35



Anexo D- Imagens da base de dados FCUP.

Classe 01



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 02



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 03



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 04



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 05



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 06



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 07



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 08



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 09



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 10



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 11



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 12



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 13



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 14



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 15



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 16



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 17



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 18



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 19



Ex. 0



Ex.1




Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 20



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 21



Ex. 0



Ex.1



Ex.2



Ex.3




Ex.4




Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 22



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 23



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5




Ex.6



Ex.7



Ex.8



Ex.9

Classe 24



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 25



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9

Classe 26



Ex. 0



Ex.1



Ex.2



Ex.3



Ex.4



Ex.5



Ex.6



Ex.7



Ex.8



Ex.9